



# **Análise automática de nuvens de pontos 3D de cabeças com Plagiocefalia Posicional**

**RICARDO JORGE RODRIGUES DE SOUSA**

Outubro de 2018

# **Análise automática de nuvens de pontos 3D de cabeças com Plagiocefalia Posicional**

**Ricardo Jorge Rodrigues de Sousa**

**Dissertação para obtenção do Grau de Mestre em  
Engenharia Informática, Área de Especialização em  
Engenharia de Software**

**Orientador: Doutora Fátima Rodrigues**

**Júri:**

Presidente:

[Nome do Presidente, Categoria, Escola]

Vogais:

[Nome do Vogal1, Categoria, Escola]

[Nome do Vogal2, Categoria, Escola] (até 4 vogais)

Porto, outubro 2018



Aos meus pais.



# Resumo

A Plagiocefalia Posicional é uma condição com uma prevalência significativa em crianças recém-nascidas. Esta condição define-se como uma distorção assimétrica do formato do crânio do bebê originária de complicações pré-natais ou de um incorreto posicionamento de descanso pós-parto.

Ortóteses cranianas são o método de tratamento mais utilizado pela sua eficácia, no entanto, estas ainda apresentam algumas limitações que, com recursos e técnicas mais atuais, poderão ser colmatadas.

Esta dissertação tem como propósito contribuir para a, automatização do processo de *design* das ortóteses que é atualmente feito de forma manual e, por isso, sujeito a falhas humanas. A modelação da ortótese craniana será conseguida através da análise das medidas antropométricas e por comparação destas com múltiplos modelos de cabeças consideradas normais.

Nesta dissertação foram desenvolvidas duas aplicações: uma capaz de determinar a partir de um modelo tridimensional (nuvem de pontos) do crânio deformado as medidas antropométricas requeridas para a modelação da ortótese e outra, que permite comparar duas nuvens de pontos, de modo a ser possível encontrar para uma cabeça com Plagiocefalia Posicional a cabeça normal mais próxima.

**Palavras-chave:** Plagiocefalia Posicional, Ortótese craniana, *Design* automático, Nuvem de pontos, *Iterative Closest Point*



# Abstract

Positional Plagiocephaly is a condition with a significant prevalence in newborn infants. This condition is defined as an asymmetric distortion of the patient skull shape originating from prenatal complications or incorrect post-partum rest positioning.

Cranial orthoses are the treatment method most used for their effectiveness, however, it still presents some limitations that, with state-of-the-art resources and techniques, can be overcome.

This dissertation aims to contribute to the automation of the design process of orthoses that is currently done manually and, therefore, subject to human failures. The modelling of cranial orthosis will be achieved by analysing the anthropometric measurements and comparing them with multiple head models considered normal.

In this dissertation, two applications were developed: one capable of determining the anthropometric measurements required from the three-dimensional model (cloud of points) of the deformed skull for the modeling of the orthosis and another, which allows comparing two nodes of points, to be possible find for a head with Positional Plagiocephaly the nearest normal head.

**Keywords:** Positional Plagiocephaly, Cranial orthosis, Automatic design, Point cloud, Iterative Closest Point





# Índice

|   |           |
|---|-----------|
| Resumo.....   | v         |
| Abstract.....   | vii       |
| Lista de Figuras.....   | xi        |
| Lista de Tabelas .....  | xiii      |
| Acrónimos e Símbolos.....   | xv        |
| <b>1 Introdução .....</b>   | <b>1</b>  |
| 1.1 Contexto .....  | 1         |
| 1.2 Problema.....   | 1         |
| 1.3 Objetivo.....   | 2         |
| 1.4 Análise de valor .....  | 2         |
| 1.5 Resultados esperados .....  | 2         |
| 1.6 Abordagem Preconizada .....   | 3         |
| 1.7 Organização do Documento .....  | 3         |
| <b>2 Contexto e Estado da arte .....</b>                                      | <b>5</b>  |
| 2.1 Contexto e problema .....   | 5         |
| 2.2 Análise de valor .....  | 6         |
| 2.2.1 Identificação de oportunidade .....                                     | 6         |
| 2.2.2 Análise de oportunidade .....   | 6         |
| 2.2.3 Geração de ideias.....  | 7         |
| 2.2.4 Seleção de ideias.....  | 7         |
| 2.2.5 Definição de conceito .....   | 7         |
| 2.2.6 <i>Business Model Canvas</i> .....                                      | 8         |
| 2.3 Abordagens Existentes .....   | 11        |
| 2.4 Tecnologia relevante .....  | 13        |
| 2.4.1 Capturas tridimensionais.....   | 13        |
| 2.4.2 <i>Point Cloud Library (PCL)</i> .....                                  | 14        |
| 2.4.3 Algoritmo K-Vizinhos-mais-Próximos (k-NN).....                          | 14        |
| 2.4.4 Árvores K-dimensionais.....   | 15        |
| 2.4.4.1 Pesquisa pelo vizinho mais próximo usando árvores k-dimensionais..... | 16        |
| 2.4.5 Algoritmo <i>Iterative Closest Point</i> .....                          | 17        |
| 2.4.6 <i>Moving Least Squares (MLS)</i> .....                                 | 19        |
| 2.4.7 <i>Point Cloud Features</i> .....                                       | 19        |
| <b>3 Soluções e abordagens existentes .....</b>                               | <b>23</b> |

|          |  |           |
|----------|--|-----------|
| 3.1      | Alinhamento de nuvens de pontos .....  | 23        |
| 3.2      | Comparação de nuvens de pontos .....   | 24        |
| 3.2.1    | Triangulação de Delaunay .....   | 25        |
| 3.2.2    | Comparações baseadas em cortes transversais e características .....                            | 25        |
|          | • Primeiro Método: Comparação de nuvens de pontos gerais .....                                 | 26        |
|          | • Segundo Método: Comparação de nuvens de pontos baseada em características .....              | 26        |
| 3.2.3    | Distância de Hausdorff .....   | 27        |
| <b>4</b> | <b>Design.....</b>   | <b>29</b> |
| 4.1      | Arquitetura .....  | 29        |
| 4.2      | Modelos de teste.....  | 31        |
| 4.3      | Implementação .....  | 33        |
| 4.3.1    | Downsampling .....   | 33        |
| 4.3.2    | Smoothing.....   | 34        |
| 4.3.3    | Alinhamento das nuvens .....   | 35        |
|          | • Cálculo das normais da superfície .....  | 36        |
|          | • Detecção dos Pontos de Interesse .....   | 37        |
|          | • Computação de <i>Features</i> .....  | 37        |
|          | • Procura de correspondências .....  | 38        |
|          | • Alinhamento refinado .....   | 39        |
| 4.3.4    | Comparação das nuvens .....  | 40        |
|          | • Distância de Hausdorff .....   | 40        |
|          | • Distância média para o vizinho mais próximo (kNN) .....                                      | 42        |
| 4.3.5    | Detecção das medidas antropométricas requeridas para a modelação da ortótese .....             | 43        |
| <b>5</b> | <b>Avaliação .....</b>   | <b>47</b> |
| <b>6</b> | <b>Conclusões.....</b>   | <b>52</b> |
| 6.1      | Limitações .....   | 53        |
| 6.2      | Trabalho futuro .....  | 53        |
|          | <b>Referências.....</b>  | <b>54</b> |
|          | <b>Apêndices.....</b>  | <b>58</b> |
|          | Apêndice A - Abordagem existente para tratamento de doentes com PP utilizando modelos 3D ..... | 60        |
|          | Apêndice B - Computação da distância de Hausdorff .....  | 62        |
|          | Apêndice C - Cálculo da distância média para o ponto mais próximo .....                        | 64        |

# Lista de Figuras

|  |    |
|--|----|
| Figura 1 – Comparação entre uma cabeça normal e uma cabeça com Plagiocefalia Posicional.   | 5  |
| Figura 2 – À esquerda, suporte cranial. À direita, criança com PP colocada sobre o suporte craniano (Rogers et al., 2008)  | 11 |
| Figura 3 – Ortótese craniana (Schwenn et al., 2002)  | 12 |
| Figura 4 – Criança com Plagiocefalia antes e depois de ser submetida ao tratamento com ortótese craniana (Clarren, 1981)   | 12 |
| Figura 5 – Medições do perímetro cefálico (vermelho) e volume cranial (verde) (Ifllaender et al., 2013)  | 14 |
| Figura 6 – Demonstração do algoritmo k-NN (Wikipedia, 2018)  | 14 |
| Figura 7 – Representação planar da árvore k-dimensional A (Bentley, 1975)  | 16 |
| Figura 8 – Exemplo de árvore k-dimensional (árvore A) (Bentley, 1975)  | 16 |
| Figura 9 – Algoritmo kNN aplicado a uma árvore k-dimensional   | 17 |
| Figura 10 – Representação da distância mínima entre os pontos das duas linhas após transformação com o algoritmo ICP (Smistad et al., 2015)  | 18 |
| Figura 11 – Região de influência para a computação PFH para o ponto $pq$ (Rusu et al., 2009)   | 20 |
| Figura 12 – Representação das coordenadas $u, v, w$ (Point Cloud Libray, 2018)   | 20 |
| Figura 13 – Transformação de uma malha irregular numa regular (Alliez et al., 2008)  | 24 |
| Figura 14 – Decomposição de uma malha de uma nuvem de pontos (A–vértices, B–arestas, C– faces)   | 24 |
| Figura 15 – Cálculo da área de discrepância num corte transversal de um modelo (Grimmer et al., 2011)  | 26 |
| Figura 16 – Distância entre $S$ e $S'$ (Oniga & Chirila, 2013)   | 28 |
| Figura 17 – Arquitetura do sistema   | 30 |
| Figura 18 – Modelo da cabeça normal  | 32 |
| Figura 19 – Base de dados de cabeças deformadas  | 32 |
| Figura 20 - Nuvem de pontos original (62711 pontos)  | 33 |
| Figura 21 – Representação da nuvem constituída por um conjunto de voxels (52082 voxels)  | 34 |
| Figura 22 – Nuvem de pontos reduzida (6569 pontos)   | 34 |
| Figura 23 – Nuvem de pontos alisada (6569 pontos)  | 35 |
| Figura 24 – Processo de alinhamento  | 36 |
| Figura 25 – Representação dos Pontos de Interesse (a preto), sobre a nuvem de pontos original (a cinzento)   | 37 |
| Figura 26 – Nuvem alvo (vermelho) e nuvem a ser alinhada (azul) antes de se iniciar o processo de alinhamento  | 38 |
| Figura 27 – Nuvens de pontos após alinhamento inicial  | 39 |
| Figura 28 – Nuvens de pontos após alinhamento refinado   | 40 |
| Figura 29 – Nuvem 1 classificada como a mais semelhante com à nuvem de referência (azul e verde representa os pontos mais semelhantes enquanto que amarelo e vermelho os mais distantes) | 42 |

|  |    |
|--|----|
| Figura 30 – Pontos de referência para as medidas antropométricas usadas na modelação da ortótese ..... | 43 |
| Figura 31 – Representação do Plano 3 a vermelho .....  | 44 |
| Figura 32 – Índice de Simetria Radial (Plank et al., 2006) .....                                       | 60 |

# Lista de Tabelas

|  |    |
|--|----|
| Tabela 1 – Modelo Canvas.....  | 10 |
| Tabela 2 – Excerto das transformações aplicadas.....   | 31 |
| Tabela 3 – Resultados do cálculo da Distância de Hausdorff das nuvens antes de serem alinhadas com a nuvem normal .....  | 40 |
| Tabela 4 – Resultados do cálculo da Distância de Hausdorff das nuvens após um alinhamento inicial para com a nuvem normal .....                                  | 41 |
| Tabela 5 – Resultados do cálculo da Distância de Hausdorff das nuvens após um alinhamento refinado para com a nuvem normal .....                                 | 41 |
| Tabela 6 – Distâncias médias de cada ponto de uma nuvem A relativamente ao ponto mais próximo da nuvem original.....   | 42 |
| Tabela 7 – Medidas antropométricas .....   | 45 |
| Tabela 8 – Transformações médias aplicadas .....   | 47 |
| Tabela 9 – Comparação dos resultados de semelhança de nuvens.....  | 48 |
| Tabela 10 – Pares concordantes e discordantes para o cálculo do coeficiente de correlação de Kendall para as comparações através da Distância de Hausdorff ..... | 49 |
| Tabela 11 - Pares concordantes e discordantes para o cálculo do coeficiente de correlação de Kendall para as comparações através da Distância dos kNN .....      | 50 |
| Tabela 12 – Quantidade de melhorias/agravamentos registadas para as quatro variáveis chave (Plank et al., 2006) .....  | 61 |



# Acrónimos e Símbolos

## Lista de Acrónimos

|               |  |
|---------------|--|
| <b>ICP</b>    | <i>Iterative Closest Point</i>                       |
| <b>2D</b>     | Duas dimensões                                       |
| <b>3D</b>     | Três dimensões                                       |
| <b>HC</b>     | Perímetro cefálico                                   |
| <b>ITK</b>    | <i>Insight Segmentation and Registration Toolkit</i> |
| <b>VTK</b>    | <i>Visualization Toolkit</i>                         |
| <b>FFE</b>    | <i>Fuzzy Front-End</i>                               |
| <b>NCD</b>    | <i>New Concept Development Model</i>                 |
| <b>FEI</b>    | <i>Front End Inovation</i>                           |
| <b>PCL</b>    | <i>Point Cloud Library</i>                           |
| <b>PLY</b>    | <i>Polygon File Format</i>                           |
| <b>PP</b>     | <i>Plagiocefalia Posicional</i>                      |
| <b>k-NN</b>   | <i>k-Nearest-Neighbor</i>                            |
| <b>k-D</b>    | k-Dimensional  |
| <b>PFH</b>    | <i>Point Feature Histograms</i>                      |
| <b>SAC-IA</b> | <i>SAmple Consensus Initial Alignment</i>            |

## Lista de Símbolos

|          |           |
|----------|-----------|
| $\Sigma$ | Somatório |
|----------|-----------|





# 1 Introdução

## 1.1 Contexto

A Plagiocefalia é um problema caracterizado pela distorção assimétrica do crânio de um recém-nascido. Estima-se que no passado, 10% das crianças saudáveis sofriam de Plagiocefalia Anterior devido a um posicionamento incorreto sendo esse o tipo de Plagiocefalia mais frequente. Atualmente, a Plagiocefalia Posicional (PP) é a mais comum, diferenciando-se da Plagiocefalia Anterior no sentido em que a deformação é na parte lateral da cabeça causada por complicações pré-natais ou aplicação de forças externas à cabeça do bebé pós-parto (Robinson & Proctor, 2009).

Esta dissertação foi desenvolvida no âmbito do projeto Ortótese Inteligente Personalizada para Plagiocefalia Posicional – SmartOrthosis (REFERÊNCIA 02/SAICT/2016 PORTUGAL 2020) que tem por objectivo o desenvolvimento de uma ortótese inteligente personalizada para correção da PP. O projecto encontra-se dividido em cinco tarefas e esta dissertação foi desenvolvida no âmbito da primeira tarefa que tem por objectivo o desenvolvimento de uma estratégia automática para determinação das medidas antropométricas sobre um modelo 3D de alta resolução da cabeça da criança, adquirido através de um sistema laser.

## 1.2 Problema

Sendo a PP um problema com uma prevalência estimada de 19.7% das crianças até aos 4 meses (Robinson & Proctor, 2009), é necessário encontrar soluções para que se possa corrigir as assimetrias reveladas.

Atualmente, a solução mais eficaz é o tratamento ortopédico através de ortóteses cranianas fabricadas através de modelos padronizados. No entanto, esta solução ainda provoca algumas complicações indesejadas, tais como lesões da pele, perda de cabelo, desconforto e ajuste desadequado durante o período de tratamento.

O período de tratamento tipicamente tem uma duração de 23 horas diárias durante um período mínimo de 3 meses (Robinson & Proctor, 2009). Existe, portanto, a necessidade de colmatar as falhas ainda existentes no tratamento deste problema uma vez que esta solução ainda

apresenta elevado potencial para ser melhorada com base nas tecnologias disponíveis atualmente.

### **1.3 Objetivo**

Tendo em conta as falhas existentes nos modelos padronizados para a criação das ortóteses cranianas, também referidas como capacetes ortopédicos, o objetivo será o de a partir de uma nuvem de pontos com as deformidades presentes na cabeça da criança, contribuir para o automatismo da modelação personalizada da ortótese através da extração de medidas antropométricas relevantes e identificação, através de comparações refinadas, da nuvem de pontos de uma cabeça normal mais semelhante à nuvem deformada.

### **1.4 Análise de valor**

Um dos passos mais importantes no tratamento da PP, é o das medições antropométricas da cabeça do paciente. Estas medições são de extrema importância, pois, servirão como base para o fabrico da ortótese e também serão o ponto de controlo para o acompanhamento do crescimento e alterações do formato craniano.

Sendo este passo realizado manualmente, encontra-se sujeito a erro humano e a um nível indesejado de precisão. Para além disto, as ortóteses atuais seguem modelos padrões podendo provocar complicações durante o tratamento ou até mesmo serem incapazes de atingir o objetivo na sua totalidade.

Encontra-se aqui uma oportunidade de aumentar a eficiência da ortótese através de um *design* automático e personalizado. O presente projeto será uma mais-valia para os especialistas uma vez que permitirá desenvolver ortóteses mais precisas e adequadas às particularidades da cabeça da criança e simultaneamente reduzir o tempo despendido nesta tarefa.

Adicionalmente beneficiará também a própria criança bem como os familiares, porque para além da prótese ser específica à cabeça da criança com PP, o que permitirá uma correção mais personalizada, também através do acoplamento de sensores na ortótese, será possível fazer o ajuste da ortótese de forma assistida, de acordo com a evolução da cabeça da criança, o que até agora não acontecia, sendo a maior dificuldade dos pais que lidam com este problema.

### **1.5 Resultados esperados**

O presente projeto tem como principais resultados um novo método de extração automática de medidas antropométricas a partir de uma nuvem de pontos da cabeça deformada e um segundo método para comparação de duas nuvens de pontos representativas das cabeças. Com o primeiro método será automatizado o procedimento de medição antropométrica, reduzindo o tempo necessário para personalizar a ortótese e eliminando erros que possam ser causados por uma medição humana. O segundo método permitirá a partir de uma base de dados de nuvens de cabeças normais encontrar a cabeça normal mais próxima da cabeça com PP podendo esta ser usada não só como modelo base na construção da ortótese, mas também

como referencial de medição da evolução ao longo do tempo, da correção realizada pela ortótese à cabeça com PP.

## 1.6 Abordagem Preconizada

As medidas antropométricas obtidas durante a modelação da cabeça do paciente, descrevem de forma eficiente a anatomia da cabeça, servirão por isso como base para identificar a anatomia mais semelhante com uma cabeça considerada normal.

Após a identificação da anatomia mais próxima, é esperado que seja elaborado uma remodelação do modelo deformado para um modelo saudável para que se possa proceder à criação da ortótese ideal.

Será, portanto, construída uma aplicação que recebe uma nuvem de pontos de uma cabeça com PP, faz a comparação dessa nuvem com um conjunto de nuvens de cabeças normais para encontrar a mais semelhante. Outra aplicação deverá ser capaz de dada uma nuvem de pontos representativa de uma cabeça humana, identificar os pontos considerados relevantes para efetuar as medições antropométricas essenciais à construção, por parte dos ortoprotésicos, da ortótese craniana.

Em seguida será necessário elaborar a prótese da cabeça deformada de encontro com a cabeça normal identificada como a mais próxima para este caso. A ortótese ideal será assim refinada automaticamente ajustando os seus limites com a cabeça deformada original.

Tendo acesso a um modelo em três dimensões (3D) da cabeça deformada do paciente e uma base de dados de cabeças consideradas normais é possível através sucessivas comparações encontrar a cabeça mais semelhante à forma em questão. Esta forma normal será usada com a forma original (deformada) na execução do algoritmo “*Iterative closest point*” (ICP) (Besl & McKay, 1992) de modo a obter o alinhamento entre ambas para posteriormente se proceder ao fabrico da ortótese com base nos resultados do alinhamento. Para a identificação dos pontos-chave antropométricos serão efetuados estudos e cálculos sobre a nuvem de pontos, tais como a identificação de pontos de referência facilmente identificáveis devido ao seu relevo em relação à superfície.

Para a elaboração desta solução será, então, seguida uma abordagem baseada em alinhamentos, comparações e transformações obtidas com a utilização do algoritmo ICP e com as potencialidades oferecidas pela biblioteca *Point Cloud Library* (Rusu & Cousins, 2011).

## 1.7 Organização do Documento

Este documento encontra-se dividido em seis capítulos principais.

O primeiro capítulo, Introdução, surge como capítulo introdutório à dissertação, onde são apresentados de uma forma resumida, o contexto e o problema proposto, o objetivo do projeto, a análise de valor, os resultados que se esperam atingir e a abordagem seguida.

No segundo capítulo, Contexto e Estado da Arte, é exposto com mais detalhe o contexto e o problema, segue-se a descrição do problema da PP, é elaborada uma análise de valor detalhada e descreve-se, em pormenor, o Estado da Arte das abordagens existentes.

O terceiro capítulo, Soluções e abordagens existentes, avalia as soluções e abordagens existentes para o problema e, com base nisso justifica as escolhas que foram tomadas.

O quarto capítulo, *Design*, apresenta, de uma forma geral, a arquitetura da aplicação desenvolvida, descrevendo os seus módulos principais e como estes se interligam entre si assim como a implementação dos algoritmos utilizados.

O quinto capítulo, Avaliação, tem como objetivo apresentar as técnicas utilizadas para a avaliação da solução, nomeadamente, a avaliação de métricas fundamentais nos resultados dos algoritmos de transformação, alinhamento e comparação de nuvens de pontos.

O último capítulo, Conclusões, incidirá principalmente na apreciação global dos resultados, explicitando as conclusões que se podem apreender do trabalho que foi conduzido. Terá também como objetivo relatar as limitações e o trabalho futuro a ser executado na continuação do projeto relatado.

## 2 Contexto e Estado da arte

### 2.1 Contexto e problema

A Plagiocefalia é um problema caracterizado pela distorção assimétrica do crânio de um recém-nascido. Este problema poderá surgir devido a complicações pré-natais ou com a aplicação de forças externa pós-parto tais como uma frequente posição incorreta de descanso uma vez que o crânio de um recém nascido apresenta relativa maleabilidade.

Este problema surge também associado a crianças com torcicolo, uma condição caracterizada por uma posição anormal e assimétrica do pescoço ou cabeça (Cooperman & Karmel-Ross, 1997).




Figura 1 – Comparação entre uma cabeça normal e uma cabeça com Plagiocefalia Posicional

Atualmente, a solução mais eficaz é o tratamento ortopédico através de ortóteses cranianas fabricadas através de medições antropométricas feitas à mão e modelos padronizados. No entanto, esta solução ainda provoca algumas complicações indesejadas, tais como lesões da pele, perda de cabelo, desconforto e ajuste desadequado durante o período de tratamento, que tipicamente tem uma duração de 23 horas durante um período mínimo de 3 meses (Robinson & Proctor, 2009).

Vivendo numa era com grandes avanços tecnológicos, é possível melhorar o processo e o tratamento dando uso a tecnologias que poderão ser úteis, tais como, medições a laser 3D da cabeça do paciente, aumentando assim a precisão destas e criando uma nuvem de pontos que poderá ser utilizada para monitorização do progresso do tratamento. Este modelo 3D poderá também servir como ponto de partida para, com o auxílio de algoritmos de alinhamento e comparações, detetar rapidamente o modelo “normal” mais semelhante dentro de uma base de dados de modelos de cabeças normais. Isto permitirá não só aumentar a eficiência do tratamento (reduzindo o risco de erro humano e criando ortóteses personalizadas), bem como, reduzir o tempo despendido durante o *design* da ortótese uma vez que este processo passará a ser realizado de uma forma automática.

## **2.2 Análise de valor**

Análise de valor é o processo de revisão e avaliação sistemática aplicada a um produto de forma a entender quais as necessidades e requisitos de um utilizador e como os satisfazer, aumentando assim o valor do produto ao menor custo possível e sem sacrificar a sua qualidade (Nicola, 2017).

Para realizar a análise de valor deste projeto foi aplicado o modelo NCD (*New Concept Development Model*). Este modelo foi desenvolvido por Peter Koen e é usado para descrever as etapas de análise, criação e inovação de um produto (Koen et al., 2014). O modelo NCD tem 5 elementos-chave: “1) Identificação de oportunidade, 2) Análise de oportunidade, 3) Geração de ideias, 4) Seleção de ideias, 5) Definição de conceito” (Koen et al., 2014).

De seguida são descritas as 5 etapas do modelo NCD no âmbito deste projeto e os métodos envolvidos em cada uma dessas etapas.

### **2.2.1 Identificação de oportunidade**

Este projeto tem como finalidade colaborar para o aumento da eficiência do tratamento da Plagiocefalia Posicional através do aumento da eficiência das ortóteses cranianas usadas para o efeito.

### **2.2.2 Análise de oportunidade**

Este problema apresenta uma prevalência de 1 em cada 7 crianças, sendo que os tratamentos tradicionais não conferem o nível desejado de correção, pelo que encontra-se aqui uma oportunidade para melhorar a correção desta deformação.

O presente projeto surge assim com a identificação da oportunidade de melhorar o tratamento atual da PP uma vez que este ainda apresenta algumas deficiências, tais como a dificuldade, a morosidade e a imprecisão no desenvolvimento da ortótese, o desconforto e complicações secundárias que podem surgir no paciente e ainda a dificuldade de acompanhar de forma rigorosa o desenvolvimento da cabeça bem como o difícil ajuste da própria ortótese ao longo do tratamento.

### **2.2.3 Geração de ideias**

O melhoramento da ortótese será obtido através de um design automático da mesma ao invés de um design manual e padronizado como é feito nos dias de hoje.

### **2.2.4 Seleção de ideias**

Após uma análise mais exaustiva desta oportunidade, foi possível concluir que esta representa uma inovação no tratamento deste problema. Esta análise foi efetuada consultando artigos científicos, conhecendo assim ao detalhe cada passo do tratamento da PP. Como resultado desta análise, surgiu a ideia de aliar métodos que já existem, como por exemplo, as modelações 3D para efeitos médicos, com algoritmos mais avançados que se encontram com um nível de maturidade significativo, como o algoritmo ICP ou algoritmos que operam sobre nuvens de pontos oferecendo uma alargada capacidade de efetuar transformações sobre as mesmas.

### **2.2.5 Definição de conceito**

As medições antropométricas serão feitas a partir de uma leitura digital da cabeça deformada, criando um modelo 3D de alta resolução baseado em modelos com nuvens de pontos. Estes modelos servirão como ponto de partida para encontrar a forma normal mais semelhante de entre uma base de dados com modelos de cabeças normais. Tendo encontrada a cabeça normal correspondente, será necessário, com recurso ao algoritmo ICP, realizar um passo de alinhamento e transformação da cabeça deformada de modo aproximar esta com a cabeça normal mais próxima. O resultado deste alinhamento e transformação resultará num modelo que posteriormente será utilizado para o fabrico da ortótese a ser usada durante o tratamento. Juntamente a esta ortótese personalizada, será acoplado um têxtil com sensores para uma monitorização contínua do desenvolvimento e das transformações da cabeça do paciente, o que facilitará o ajuste da ortótese, resolvendo uma das maiores dificuldades dos pais que lidam com este problema.

Sendo esta uma ideia inovadora no tratamento da PP, a concorrência não se considera relevante aumentando assim o potencial de mercado, sendo este composto sobretudo por ortoprotésicos com desejo de produzir ortóteses mais eficazes, eliminando a necessidade de seguir modelos padronizados, enquanto vê a complexidade do processo de *design* reduzida uma vez que, sendo este *design* automático, já não necessita de efetuar medidas antropométricas meticulosas ao paciente no decurso do tratamento, deixando esse trabalho para o *scanner* 3D. Os pacientes com PP, seriam os principais beneficiadores deste projeto, tendo acesso a um tratamento, mais eficaz e confortável, tal como os seus cuidadores que,



devido às informações recolhidas pelos sensores acoplados no têxtil da prótese, terão mais facilidade em saber como e onde deverão ajustar a ortótese.

### 2.2.6 *Business Model Canvas*

Inicialmente proposto em 2008 por Alexander Osterwalder em “The Business Model Ontology - A Proposition In A Design Science Approach”, este modelo apresenta uma descrição clara em forma de mapa visual dos elementos respeitantes a um modelo de negócio. Este modelo é decomposto em nove blocos cobrindo quatro áreas principais do negócio: clientes, oferta, infraestrutura e viabilidade financeira (Barquet et al., 2011).

Para este projeto, o Modelo de Negócio Canvas encontra-se ilustrado na Tabela 1, estando construído da seguinte forma:

- O segmento de clientes são os pacientes com PP sendo que é a estes que o projeto pretende resolver os principais problemas, para além deles, esta solução poderá também ser do interesse de ortoprotésicos como auxílio no processo de desenvolvimento da ortótese.
- A proposta de valor responderá às necessidades essenciais dos pacientes com PP pois aumentará a eficiência da ortótese e do seu conforto, permitirá também um acompanhamento mais personalizado e preciso em relação às transformações que vão ocorrendo. Para os ortoprotésicos, reduzirá a complexidade do *design* enquanto permite que estas sejam mais personalizadas.
- Os canais de comunicação serão os tradicionais com os pacientes uma vez que as consultas médicas se revelam indispensáveis durante o tratamento.
- A relação com o cliente será feita através do constante acompanhamento dos resultados do tratamento com esta ortótese personalizada uma vez que, mediante o crescimento e transformações da cabeça, a ortótese necessitará de ser ajustada de acordo com cada fase.
- As fontes de receita serão as vendas das referidas ortóteses cranianas.
- Os recursos Chave para o desenvolvimento desta solução são o *scanner* 3D, modelos das cabeças deformadas lidas pelo *scanner*, uma base de dados de modelos de cabeças normais para comparação, alinhamento e transformações necessárias a aplicar durante o desenvolvimento da solução e ainda o *software* necessário capaz de interpretar a informação recolhida e desenvolver a solução.
- As atividades chave serão a modelação 3D da cabeça deformada, transformação deste modelo com base no modelo da cabeça normal mais semelhante encontrada pela aplicação a desenvolver e ainda a construção das ortóteses com base no modelo transformado da cabeça deformada.
- Os parceiros chave neste projeto serão a empresa têxtil responsável por produzir um têxtil com sensores que será usado em conjunto com a ortótese para monitorização

continua durante o tratamento, médicos especializados que fornecerão as informações e o conhecimento necessário e ainda os fabricantes das ortóteses.

- A Estrutura de custos será essencialmente na aquisição de todo o material necessário para desenvolvimento, como o *scanner* 3D e o *software*, a construção do têxtil de sensores e a construção da ortótese.

Tabela 1 – Modelo Canvas

|   |  |  |   |   |
|---|--|--|---|---|
| <b>Parceiros chave</b> <ul style="list-style-type: none"><li>• Empresa têxtil para produção de um têxtil com sensores</li><li>• Médicos especializados</li><li>• Fabricantes de ortóteses</li></ul>     | <b>Atividades chave</b> <ul style="list-style-type: none"><li>• Modelação da cabeça deformada</li><li>• Transformação do modelo da cabeça com base nas cabeças normais</li><li>• Construção de ortóteses</li></ul> | <b>Proposta de valor</b> <ul style="list-style-type: none"><li>• Aumento da eficiência da ortótese</li><li>• Redução do tempo de <i>design</i> da ortótese</li></ul> | <b>Relação com o cliente</b> <ul style="list-style-type: none"><li>• Acompanhamento dos resultados</li></ul>        | <b>Segmento de clientes</b> <ul style="list-style-type: none"><li>• Pacientes com Plagiocefalia Posicional</li><li>• Ortoprotésicos</li></ul> |
|   | <b>Recursos chave</b> <ul style="list-style-type: none"><li>• Scanner 3D</li><li>• Modelos 3D das cabeças deformadas</li><li>• Modelos 3D de cabeças normais</li><li>• <i>Software</i> necessário</li></ul>        |  | <b>Canais de comunicação</b> <ul style="list-style-type: none"><li>• Consultas médicas</li><li>• Reuniões</li></ul> |   |
| <b>Estrutura de custos</b> <ul style="list-style-type: none"><li>• Aquisição <i>scanner</i> 3D</li><li>• <i>Software</i></li><li>• Construção dos sensores</li><li>• Construção das ortóteses</li></ul> |  |  | <b>Fontes de receita</b> <ul style="list-style-type: none"><li>• Venda das ortóteses</li></ul>                      |   |

## 2.3 Abordagens Existentes

No sentido de corrigir este problema, e tendo em conta que a cabeça de um recém-nascido é ainda algo maleável, um conjunto de forças são aplicadas para que a cabeça assuma uma forma normal.

Num estudo (Moss, 1997) efetuado em sessenta e seis crianças com deformações médias a moderadas, foram realizadas um conjunto de técnicas de reposicionamento supervisionado da cabeça do bebé enquanto este se encontrava deitado. Apenas uma criança não mostrou melhorias tendo havido, portanto, a necessidade de avançar para o tratamento através de ortóteses cranianas. Contudo, um outro estudo efetuado (Rogers et al., 2008) demonstrou que usando um suporte craniano, um dispositivo almofadado elaborado por ortoprotésicos aumentava consideravelmente a eficácia do tratamento em crianças com menos de quatro meses. (Robinson & Proctor, 2009)



Figura 2 – À esquerda, suporte cranial. À direita, criança com PP colocada sobre o suporte craniano (Rogers et al., 2008)

Apesar dos métodos acima mencionados, existe ainda a possibilidade de, em deformações mais acentuadas, onde o reposicionamento se revele ineficaz após seis meses, ser necessário recorrer às ortóteses cranianas. Estas ortóteses cranianas são capacetes de plástico fabricados a partir de um molde realizado à cabeça do bebé. Este capacete envolve a cabeça do bebé estimulando o crescimento da cabeça em pontos críticos e aplicando pressão nas zonas deformadas para as tentar corrigir. Com o desenvolvimento da própria cabeça, este capacete deverá ser ajustado para corresponder aos objetivos definidos para a cabeça. Num estudo realizado (O'Broin et al., 1999) concluiu-se, a partir de um questionário feito às famílias das crianças com este problema, que 85% destas revelaram melhorias significativas. Num estudo realizado (Teichgraeber et al., 2004), entre 1994 e 1999, e posteriormente publicado em 2004, foram efetuadas comparações entre dois tipos de tratamento para crianças com Plagiocefalia. De entre um conjunto de 360 crianças, 132 foram tratadas apenas com a correção da sua posição enquanto que 228 foram tratadas usando as ortóteses cranianas, sendo conclusivo que estas últimas mostraram melhorias significativas, na ordem dos 4.7 mm (crianças com idade superior a 6 meses) a 5.6 mm (crianças com idade inferior a 6 meses) em assimetrias na zona

da testa e uma redução de 1.2 mm (crianças com idade inferior a 6 meses) a 1.8 mm (crianças com idade superior a 6 meses) em assimetrias orbitais.




Figura 3 – Ortótese craniana (Schwenn et al., 2002)




Figura 4 – Criança com Plagiocefalia antes e depois de ser submetida ao tratamento com ortótese craniana (Clarren, 1981)

Atualmente, esta ortótese é desenhada manualmente através das medições antropométricas por um especialista carecendo, assim de uma precisão elevada e estando sujeita a erros humanos.

## 2.4 Tecnologia relevante

O processo de *design* da ortótese craniana para pacientes com PP é um trabalho manual efetuado por um técnico especialista (O'Broin et al., 1999), contudo, aliando a captura tridimensional (3D) das dimensões da cabeça de um bebé com algoritmos de comparação e alinhamento de nuvens de pontos e modelos 3D será possível anular o erro humano a que este *design* está sujeito.

Existem atualmente mecanismos para efetuar capturas tridimensionais das dimensões da cabeça de uma criança recém-nascida. Estas capturas são de particular importância em crianças com deformidades cranianas uma vez que as medições manuais podem não refletir adequadamente o volume cranial, levando a que crianças com perímetro cefálico (*HC* na literatura) semelhantes, apresentem volumes consideravelmente distintos. (Ifflaender et al., 2013).

Os algoritmos de alinhamento e comparação permitirão que de entre um conjunto de modelos de cabeças normais, seja encontrada a mais semelhante à cabeça deformada. Esta servirá como modelo base do algoritmo ICP que, através do alinhamento entre as duas superfícies (cabeça normal e cabeça deformada) efetue transformações no modelo da cabeça deformada de modo a encontrar as assimetrias mais acentuadas, avaliar se, de facto, a cabeça normal é a mais semelhante com a deformada e ainda servir como base para a construção da ortótese.

### 2.4.1 Capturas tridimensionais

A caracterização do crescimento craniano e das alterações do formato da cabeça através da medição manual do perímetro cefálico e do volume craniano é insuficiente, uma vez que estas medidas não representam necessariamente o formato 3D do crânio logo existe a hipótese de induzir em novos erros e fazer um acompanhamento impreciso, assim, os *scanners* 3D assumem uma importância fulcral no tratamento da PP. (Ifflaender et al., 2013)

*Scanners* laser não-invasivos capturam um modelo 3D da cabeça do paciente em cerca de dois segundos, posicionando quatro linhas ao longo da circunferência do crânio enquanto oito câmaras constroem a superfície 3D com uma margem de erro inferior a 1 mm (Ifflaender et al., 2013).




Figura 5 – Medições do perímetro cefálico (vermelho) e volume cranial (verde) (Ifflaender et al., 2013)

#### 2.4.2 Point Cloud Library (PCL)

*Point Cloud Library* é uma biblioteca de processamento de nuvens de ponto 2D e 3D implementada em C++ (Rusu & Cousins, 2011).

Esta biblioteca será fundamental uma vez que os modelos lidos pelo *scanner* se encontram no formato *PLY (Polygon File Format)*, sendo responsabilidade desta biblioteca a sua transformação para um conjunto de dados adaptados para que se possam aplicar algoritmos de transformação, comparação e alinhamento das nuvens de pontos através de vários métodos que já se encontram implementados.

#### 2.4.3 Algoritmo K-Vizinhos-mais-Próximos (k-NN)

Este algoritmo classifica um ponto de dados consoante os tipos de dados que se encontram mais próximo, dentro de um conjunto com  $k$  elementos.




Figura 6 – Demonstração do algoritmo k-NN (Wikipedia, 2018)

Na Figura 6 o ponto verde representa o elemento a classificar. Este poderá pertencer aos quadrados azuis ou à classe dos triângulos vermelhos. Se  $k = 3$  (círculo sólido), então a amostra deverá ser classificada como “triângulo vermelho” uma vez que dentro dos  $k$ -vizinhos-mais-próximos, esta seja a classe com maior relevância. Pelo contrário, caso  $k = 5$  (círculo tracejado), então o elemento deverá ser classificado como “quadrado azul” uma vez que estes se encontram em maior número dentro da representação dos  $k$ -vizinhos-mais-próximos.

Um dos aspetos mais importantes deste algoritmo, é a escolha do valor de  $k$ , pois, afeta diretamente o desempenho deste algoritmo. Caso este valor seja reduzido, o algoritmo poderá ser afetado pelo ruído de dados existente, ao invés, caso este valor seja demasiado alto fará com que existam bastantes tipo de dados nas proximidades, havendo assim a possibilidade de obtenção de resultados incorretos.

Dentro de cada grupo de nuvens de pontos relativas a cabeças normais, será usado o algoritmo  $k$ -NN para encontrar o modelo de cabeça normal mais próximo com o da cabeça com PP. Para tal, será necessário previamente transformar a nuvem de pontos numa árvore  $k$ -dimensional para servir de ponto de entrada para o algoritmo  $k$ -NN.

#### 2.4.4 Árvores K-dimensionais

Árvores K-dimensionais são estruturas de dados binárias usadas para organizar um número de pontos de informação num espaço com dimensão de  $K$ . Cada nó contém dois apontadores (filhos) que são nulos ou que apontam para outro nó da árvore, além disso, cada nó encontra-se associado a um discriminador ( $D$ ), isto é, um valor inteiro entre 0 e  $k-1$  inclusive, partilhado por todos os nós no mesmo nível sendo que a raiz da árvore possui o discriminador 0. Cada nó da árvore é simultaneamente a raiz de uma subárvore composta com os nós aos quais aponta (Bentley, 1975).

Para a construção de uma árvore K-dimensional inicialmente um nó é definido como a raiz, este ponto estará alinhado pelo eixo do X. Seguidamente seleciona-se um novo ponto e compara-se o seu valor de X em comparação com a sua raiz, se este valor for maior ao igual ao da sua raiz será colocado no lado direito da subárvore com  $D = D_{\text{Raiz}} + 1$ , caso contrário ficará no lado esquerdo, este valor será alinhado pelo eixo do Y. O processo é repetido até toda a informação estar representada como nós da árvore.

A Figura 7 e Figura 8 representam um exemplo da organização de um conjunto de informação sob uma árvore K-dimensional. Tendo o conjunto de pontos  $A=(50,50)$ ,  $B=(10,70)$ ,  $C=(80,85)$ ,  $D=(25,20)$ ,  $E=(40,85)$ ,  $F=(70,85)$ ,  $G=(10,60)$  e sendo o Ponto A a raiz da árvore (Discriminador = 0), temos:

$X_A > X_B$  e  $X_A < X_C$ , logo o ponto B será colocado à esquerda de A e C à direita com o discriminador de 1;

Sendo B a raiz de uma subárvore e estando alinhado por Y, temos:

$Y_B > Y_D$  e  $Y_B < Y_E$ , logo o ponto D será colocado à esquerda de B e E à direita com o discriminador de 2;

Sendo D a raiz de uma subárvore e estando alinhado por X, temos:



$X_D > X_G$ , logo o ponto G será colocado à esquerda de D com o discriminador de 3;

Chegando o fim do conjunto de dados passaremos para o lado direito da raiz original, onde temos C como a raiz de uma sub-árvore e o ponto F ainda por colocar:

$Y_C = Y_F$ , logo o ponto F será colocado à direita de C com o discriminador de 2;




Figura 7 – Representação planar da árvore k-dimensional A (Bentley, 1975)




Figura 8 – Exemplo de árvore k-dimensional (árvore A) (Bentley, 1975)

#### 2.4.4.1 Pesquisa pelo vizinho mais próximo usando árvores k-dimensionais

Aplicado sobre este tipo de árvores, o algoritmo k-NN procura encontrar o ponto mais próximo na árvore relativamente a um ponto específico, de forma eficiente, utilizando as propriedades da árvore eliminando grandes porções do espaço de pesquisa.

Para o encontrar o ponto mais próximo relativamente ao ponto P, recursivamente, o algoritmo percorre a árvore a partir da raiz, em cada nó é avaliado qual dos filhos se encontra mais próximo do ponto P eliminando assim uma área da árvore (Friedman et al., 1977).

A Figura 9 representa a aplicação do algoritmo kNN sobre a árvore de exemplo da Figura 7 e para encontrar o vizinho mais próximo do ponto P. Neste exemplo é possível classificar o ponto D como sendo o mais próximo de P.

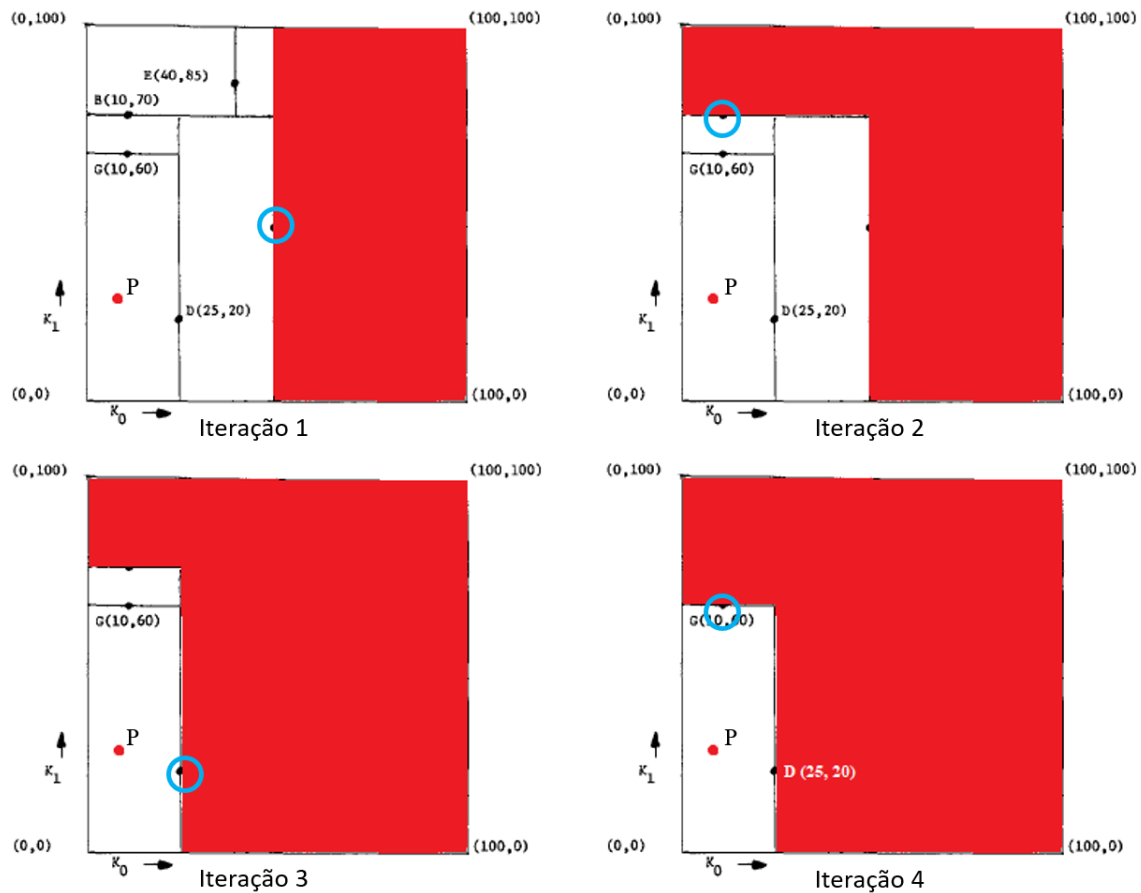


Figura 9 – Algoritmo kNN aplicado a uma árvore k-dimensional

A cada iteração temos com um círculo azul a representação do nó sob o qual a pesquisa era efetuada. A vermelho, as áreas de pesquisa que a cada iteração vinham a ser eliminadas.

#### 2.4.5 Algoritmo *Iterative Closest Point*

O algoritmo ICP será de particular importância no desenvolvimento da solução, pois será com recurso ao mesmo que será possível efetuar alinhamento entre a cabeça deformada e a cabeça normal escolhida para entender onde se encontram as principais deformações e avaliar se a cabeça normal escolhida é efetivamente a que mais se assemelha à cabeça deformada para proceder ao fabrico da ortótese.

Este algoritmo é atualmente o método dominante para alinhamento, baseando-se inteiramente na geometria das nuvens de pontos procurando, iterativamente reduzir a distância média entre as mesmas. Inicialmente, o algoritmo começa com duas nuvens de pontos e uma estimativa inicial grosseira do corpo rígido pretendido. Iterativamente, o algoritmo refina a transformação de forma a minimizar a distância entre os pontos das duas nuvens de pontos

de entrada fazendo assim com que os diferentes modelos assumam a tendência de convergir (Rusinkiewicz & Levoy, 2001). Posto isto, é aplicada uma transformação numa das superfícies da cabeça com deformação que modifica essa superfície para melhor corresponder à superfície da cabeça normal (Besl & McKay, 1992).




Figura 10 – Representação da distância mínima entre os pontos das duas linhas após transformação com o algoritmo ICP (Smistad et al., 2015).

Dadas duas nuvens de pontos  $S_1$  e  $S_2$ , o algoritmo encontrará a transformação de  $S_1$  para  $S_2$ , sendo  $\{(s_i^1, s_i^2)\}_{i=1}^N$  o conjunto de pares mais próximos para  $S_1$  e  $S_2$ . Durante a execução do algoritmo a distância média entre as nuvens de pontos é minimizada (Dyshkant, 2013):

$$E = \frac{1}{N} \sum_{i=1}^N d(s_i^1, s_i^2) \rightarrow \min \quad (1)$$

Onde  $d$  é a distância Euclidiana entre dois pontos.

Para calcular a distância entre o ponto  $s^1 \in S_1$  e a nuvem de pontos  $S_2$ , no algoritmo original de (Besl & McKay, 1992), a distância “ponto-a-ponto” foi utilizada:

$$\rho(s^1, S_2) = \min_{s^2 \in S_2} d(s^2, s^1) \quad (2)$$

Já em (Chen & Medioni, 1991) foi proposta a distância “ponto-a-plano” implicando o conhecimento prévio das normais de superfície de cada ponto de  $S_1$  e  $S_2$ . Neste caso, a soma das distâncias quadradas entre  $s_i^1$  e o plano  $P_i^2$ , perpendicular a  $S_2$  em  $s_i^2$  sobre todos os pares de pontos próximos  $(s_i^1, s_i^2)$  é minimizada (Dyshkant, 2013):

$$E = \sum_{i=1}^N H^2(s_i^1, P_i^2) \rightarrow \min \quad (3)$$

Onde  $H(s, P)$  é a distância Euclidiana entre  $s$  e plano  $P$ .

Enquanto que na abordagem “ponto-a-plano” o erro associado a influência de pares de pontos errados é menor, esta tem a desvantagem de ser altamente dependente da posição relativa inicial de  $S_1$  e  $S_2$  (Dyshkant, 2013).

Iterativamente o algoritmo ICP procura (He et al., 2017):

1. Encontrar pontos correspondentes nas duas nuvens com menor distância;
2. Calcular as matrizes de rotação e translação a ser aplicada de modo a reduzir a distância e a métrica de erro associada;
3. Aplicar as transformações calculadas na nuvem de pontos a ser alinhada;
4. Atualizar o valor do erro e verificar se este já se encontra dentro do limite definido.

A principal vantagem do algoritmo ICP é a simplicidade de implementação enquanto a desvantagem é uma forte dependência à aproximação inicial dos objetos e a elevada complexidade computacional na busca dos pares mais próximos  $\{(s_i^1, s_i^2)\}_{i=1}^N$  (Dyshkant, 2013).

Para o desenvolvimento desse projeto serão utilizadas as implementações *open-source* em C++ do ICP das bibliotecas *Insight Segmentation and Registration Toolkit* (ITK), *Visualization Toolkit* (VTK) e *Point Cloud Library* (PCL).

ITK é um *toolkit* para efetuar a segmentação de imagens, isto é identificar e classificar informações encontradas numa amostra visual, tais como modelos 3D adquiridos através de *scanners* médicos (Insight Software Consortium, 2018), enquanto que o VTK é um *toolkit* para computação gráfica 3D, modelação, processamento de imagens e visualizações científicas (Kitware, 2018).

#### **2.4.6 Moving Least Squares (MLS)**

*Moving Least Squares* é um método de reconstrução de superfícies usado para suavizar ou efetuar a reamostragem de superfícies ruidosas, isto é, com elevado grau de irregularidade. O surgimento destas irregularidades é frequentemente originado por pequenos erros cometidos durante o processo de leitura e construção da nuvem de pontos. Apresentando uma elevada complexidade para remoção do ruído através de análise estatística existe a necessidade recorrer a algoritmos de reamostragem tais como o MLS. Este algoritmo tenta recriar partes ruidosas e partes em falta da superfície através de interpolações polinomiais entre os pontos envolventes.

#### **2.4.7 Point Cloud Features**

*Feature* é uma característica relevante na representação de uma nuvem de pontos, tal como curvatura, normais de superfície e densidade que servirá como ponto de partida para o alinhamento das cabeças uma vez que possibilitará encontrar correspondências entre *features* em diferentes nuvens de pontos.

Uma forma de identificar estas *features* é através da computação de *Point Features Histograms (PFH) descriptors*. PFH são *features* informativas e invariantes que representam as propriedades da superfície subjacente num ponto  $p$ . A sua computação é baseada na combinação das relações de entre os  $k$ -vizinhos-mais-próximos de  $p$  incorporando as suas coordenadas  $\langle x, y, z \rangle$  e as normais da superfície  $\langle nx, ny, nz \rangle$ , com isto, tenta-se capturar o melhor possível as variações da superfície tendo em conta todas as mudanças de direção das normais estimadas.




Figura 11 – Região de influência para a computação PFH para o ponto  $p_q$  (Rusu et al., 2009)

O diagrama da Figura 11 representa a região de influência da computação PFH para o ponto  $p_q$  no centro de uma esfera em 3D com um raio  $r$  onde todos os seus  $k$ -vizinhos estão interligados numa rede. O descritor PFH final é computado como um histograma de relações entre todos os pares de pontos na vizinhança (Rusu et al., 2009). Para o cálculo da diferença relativa entre dois pontos  $p_i$  e  $p_j$  e as normais associadas  $n_i$  e  $n_j$  é definida a estrutura fixa de coordenadas  $\langle u, v, w \rangle$ :

$$u = n_s \quad (4)$$

$$v = u \times \frac{(p_t - p_s)}{\|p_t - p_s\|_2}$$

$$w = u \times v$$




Figura 12 – Representação das coordenadas  $\langle u, v, w \rangle$  (Point Cloud Library, 2018)

Com base nesta estrutura de coordenadas pode-se calcular a diferença entre as normais  $n_s$  e  $n_t$  expressa com recurso a um conjunto de variações angulares:

$$\begin{aligned}\alpha &= v \times n_t \\ \Phi &= u \times \frac{(p_t - p_s)}{d} \\ \theta &= \arctan(w \times n_t, u \times n_t)\end{aligned}\tag{5}$$

onde  $d$  representa a distância Euclidiana entre dois pontos  $p_s$  e  $p_t$ ,  $d = \|p_t - p_s\|_2$ .

Para cada par de pontos na k-vizinhança é calculado o quádruplo  $\langle \alpha, \Phi, \theta, d \rangle$  reduzindo os doze valores de um par de pontos (coordenadas  $\langle x, y, z \rangle$  e as suas normais) para apenas quatro.

A representação final do PFH para o ponto  $p_q$  é obtida com a inserção do conjunto de todos os quádruplos  $\langle \alpha, \Phi, \theta, d \rangle$  pertencentes num histograma (Rusu et al., 2009) .



## 3 Soluções e abordagens existentes

Como em qualquer trabalho de desenvolvimento de um projeto, é fulcral que seja previamente elaborado um estudo das soluções e abordagens existentes com o objetivo de avaliar e construir uma base de trabalho sólida. Assim sendo, este capítulo tem como propósito, apresentar a investigação que foi efetuada, avaliação das abordagens já existentes e justificar escolhas e decisões que foram tomadas. A abordagem apresentada incidirá principalmente no alinhamento e comparação de nuvens de pontos tridimensionais, contudo, no Apêndice A deste documento encontra-se descrito um estudo realizado (Plank et al., 2006) acerca dos benefícios do tratamento da PP com recurso a modelos tridimensionais capturados através de um *scanner* de alta resolução.

### 3.1 Alinhamento de nuvens de pontos

Um dos grandes problemas relacionado com o trabalho com nuvens de pontos tridimensionais é que frequentemente estas não se encontram alinhadas, impossibilitando assim a prática de comparações entre as mesmas. Para ultrapassar este problema e diminuir a distância entre duas nuvens de pontos, existem essencialmente dois tipos de soluções: as baseadas no algoritmo ICP e outra na seleção de *features* comuns entre as duas nuvens de pontos a alinhar (Basdogan & Oztireli, 2008).

O alinhamento baseado na seleção de *features* procurar encontrar características relevantes em ambas as nuvens de pontos, assentando na premissa que um pequeno número de correspondência entre *features* é suficiente para efetuar o alinhamento. Em relação ao ICP, este método apresenta como vantagens que (Basdogan & Oztireli, 2008):

- Não é necessário percorrer todos os pontos das nuvens para encontrar pares correspondentes, sendo apenas necessário procurar nas *features*. Deste modo, pontos redundantes ou irrelevantes não afetam o alinhamento;
- É independente do alinhamento inicial das nuvens de pontos, ao contrário do ICP que requer que exista previamente um alinhamento ainda que grosseiro.



Em contrapartida:

- Pode ser complicado encontrar *features* semelhantes em ambas as nuvens de pontos e,
- Geralmente estes tipo de métodos são mais lentos que os baseados no algoritmo ICP.

### 3.2 Comparação de nuvens de pontos

Atualmente existem inúmeros métodos de comparação de nuvens de pontos onde muitos destes executam inicialmente a transformação de malhas irregulares para uma malha regular (Figura 13). Uma malha de uma nuvem de pontos representa um conjunto de vértices (pontos da nuvem), arestas (ligação entre dois pontos) e faces (conjuntos fechados de arestas) criadas a partir de uma nuvem de pontos (Figura 14). Dada esta transformação, estes métodos procuram efetuar a correspondência e a comparação dos nós da superfície.




Figura 13 – Transformação de uma malha irregular numa regular (Alliez et al., 2008)

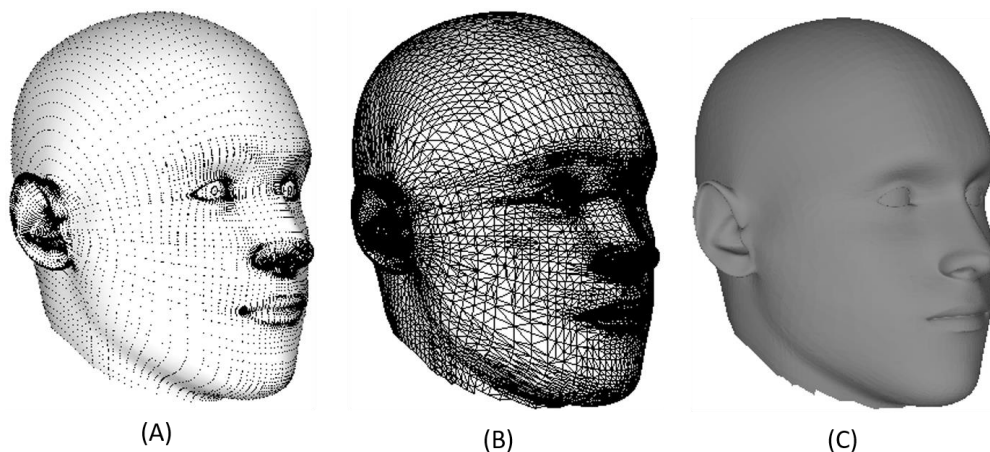


Figura 14 – Decomposição de uma malha de uma nuvem de pontos (A–vértices, B–arestas, C–faces)

Durante a transformação inicial das malhas existe o problema de escolher os valores ideais da malha regular o que conduz a um número significativo de cálculos de modo a atingir uma

precisão aceitável da superfície de aproximação. A maioria destes métodos partem também da assunção que para cada nó existe um nó correspondente na nuvem a comparar, enquanto que outros baseiam-se na comparação de *features*.

Um dos algoritmos básicos para encontrar correspondências entre superfícies é o algoritmo ICP que iterativamente procura reduzir a distância média entre duas nuvens de pontos. Este algoritmo requer uma estimativa inicial grosseira que vai sendo gradualmente refinada durante a execução do algoritmo.

### 3.2.1 Triangulação de Delaunay

Em 2013, (Dyshkant, 2013) foi proposto um método de comparação de superfícies usando a Triangulação de Delaunay.

De forma sucinta, os principais passos deste algoritmo são:

1. Construção das triangulações de Delaunay  $T_1$  e  $T_2$ ;
2. Construção da árvore geradora mínima euclidiana das triangulações de Delaunay;
3. Localização de cada malha  $g_1$  na triangulação construída na outra malha  $g_2$  e vice-versa;
4. Interpolação de duas funções representativas das superfícies em cada uma das malhas;
5. Construção da triangulação comum  $T$ ;
6. Comparação das funções nas células separadas da triangulação  $T$ .

O resultado deste algoritmo é uma métrica que mede o nível de semelhança entre duas malhas distintas. Esta abordagem apresentou resultados satisfatórios tendo sido comprovado com múltiplas experiências computacionais com dados tridimensionais (Dyshkant, 2013).

### 3.2.2 Comparações baseadas em cortes transversais e características

Num outro estudo (Grimmer et al., 2011) foram considerados dois métodos de comparação de nuvens de pontos tridimensionais. O primeiro requer apenas os objetos, lidos por um *scanner*, representados sobre a forma de modelos tridimensionais de uma nuvem de pontos. Contrariamente a métodos já estudados, este utiliza não só a superfície do modelo, mas também o volume do mesmo. O segundo método é específico para modelos cujas principais características, *features*, estejam identificadas e com um determinado peso atribuído de acordo com a sua significância para com a comparação.

De modo a ser possível efetuar uma comparação eficiente é necessário garantir que a posição e orientação dos modelos esteja normalizada uma vez que poderá haver discrepâncias durante a leitura dos modelos. Para este estudo, o autor definiu que para cada modelo a origem do referencial deveria encontrar-se no centro de gravidade do mesmo, além de enquadrar os eixos  $x$ ,  $y$  e  $z$  em determinadas direções no modelo de modo a normalizar a orientação dos mesmos.

- **Primeiro Método: Comparação de nuvens de pontos gerais**

Este primeiro método tem como objetivo criar uma técnica independente das características do objeto que quantifique as diferenças entre os mesmos. Após a normalização, as discrepâncias do volume dos objetos são calculadas usando os seguintes passos: primeiramente o objeto 3D é expresso como um conjunto de cortes transversais perpendiculares ao eixo de alongamento previamente calculado usando a Análise de componentes principais, reduzindo assim o problema para um cenário 2D. Este passo é possível de se efetuar uma vez que a normalização garante que os cortes transversais correspondam à mesma posição em ambos os modelos. Reduzindo a um problema 2D, reduz-se também a complexidade do problema bem como o tempo de cálculo. Para cada corte transversal é calculada a área de discrepância (representada a vermelho na Figura 15). Para obter o valor final da discrepância entre dois modelos são multiplicadas as áreas de discrepância totais pelo incremento do eixo z entre cada dois cortes adjacentes (Grimmer et al., 2011).




Figura 15 – Cálculo da área de discrepância num corte transversal de um modelo (Grimmer et al., 2011)

Apesar de medir as semelhanças entre dois modelos de forma relativamente intuitiva e significativa tem a desvantagem de tratar todas as diferenças da mesma forma não permitindo que umas assumam maior peso que outras (Grimmer et al., 2011).

- **Segundo Método: Comparação de nuvens de pontos baseada em características**

Este método foi criado de forma a permitir que determinadas características do modelo, tais como comprimento ou altura de algum ponto específico, assumam maior importância que outras para efetuar a comparação. Primeiramente é essencial identificar e classificar  $N$  características de acordo com a sua importância. Em seguida, procede-se ao seu agrupamento das características em grupos cada um correspondente a um nível de importância distinto. Cada valor das diferentes características é então multiplicado por um fator associado ao grupo a que se insere e colocado num vetor com dimensão  $N$ . Este vetor é então representado como um ponto num espaço com dimensão de  $N$ . A semelhança entre dois modelos é dada pela distância

euclidiana entre dois destes dois vetores, ambos representando distintos modelos (Grimmer et al., 2011).

Ambos os métodos provaram que é possível efetuar comparações entre nuvens de pontos de forma eficaz e apresentado resultados satisfatórios tendo apenas os modelos que foram lidos pelo *scanner* bem como recorrendo a um estudo das principais características do objeto em questão (Grimmer et al., 2011).

### 3.2.3 Distância de Hausdorff

A Distância de Hausdorff é uma métrica utilizada para quantificar a diferença entre dois conjuntos de pontos sem a necessidade de estabelecer uma correspondência de um-para-um entre eles, apresentando-se esta como uma das vantagens desta métrica, para o cálculo da diferença, uma vez que é frequente duas nuvens não possuírem exatamente o mesmo número de pontos (Zhang et al., 2017).

Esta métrica representa o desvio máximo entre dois modelos, medindo o quão afastados dois conjuntos de pontos se encontram um do outro (Oniga & Chirila, 2013).

Considerando dois conjuntos de pontos não-vazios  $A = \{x_1, x_2, \dots, x_n\}$  e  $B = \{y_1, y_2, \dots, y_m\}$ , a distância entre  $A$  e  $B$  é definida como:

$$h(A, B) = \max_{x \in A} (\min_{y \in B} ||x - y||) \quad (6)$$

Não sendo esta uma distância simétrica, ou seja,  $h(A, B) \neq h(B, A)$ , a distância de Hausdorff é dada como:

$$H(A, B) = \max(h(A, B), h(B, A)) \quad (7)$$

onde,

$$h(A, B) = \max_{x \in A} (\min_{y \in B} ||x - y||) \quad (8)$$

$$h(B, A) = \max_{y \in B} (\min_{x \in A} ||y - x||)$$

A distância simétrica de Hausdorff é mais precisa na quantificação das diferenças uma vez que a distância unilateral pode induzir numa subestimação da distância entre duas superfícies. Como apresentado na Figura 16,  $h(S, S') = A - D \leq h(S', S) = B - A$ .




Figura 16 – Distância entre  $S$  e  $S'$  (Oniga & Chirila, 2013)

Quanto menor for o valor da distância de Hausdorff mais semelhantes são as nuvens de pontos.

## 4 Design

Com base no objetivo do projeto, contribuir para o *design* automático das ortóteses cranianas, será elaborada uma solução que o procure alcançar. Esta solução passará principalmente pela exploração do algoritmo ICP e de operações sobre nuvens de pontos.

Nuvens de pontos de várias cabeças normais e, pelo menos, uma nuvem de pontos de uma cabeça anormal são considerados recursos essenciais para o desenvolvimento da solução, pois, será sobre estes que assentará o desenvolvimento. Dado um modelo de uma cabeça que apresente deformidades, é expectável que a aplicação seja capaz de encontrar o modelo normal mais parecido com a cabeça deformada. Além disso, será também criada outra aplicação capaz de extrair as medidas antropométricas mais relevantes que serão posteriormente usadas na elaboração da ortótese.

Este projeto será desenvolvido em C++ com recurso às bibliotecas VTK, ITK e PCL também elas desenvolvidas em C++.

### 4.1 Arquitetura

O projeto inclui um módulo responsável pela leitura, outro pela transformação das nuvens de pontos PLY, dois módulos para aplicação dos algoritmos que operam sobre a nuvem de pontos, tais como algoritmos de alinhamento e comparações, onde com base na nuvem de pontos de uma cabeça deformada será escolhido um modelo de uma cabeça normal mais próximo através da aplicação do algoritmo ICP. Além disso, o módulo, CloudPointExtractor, será capaz de extrair as medidas antropométricas necessárias.

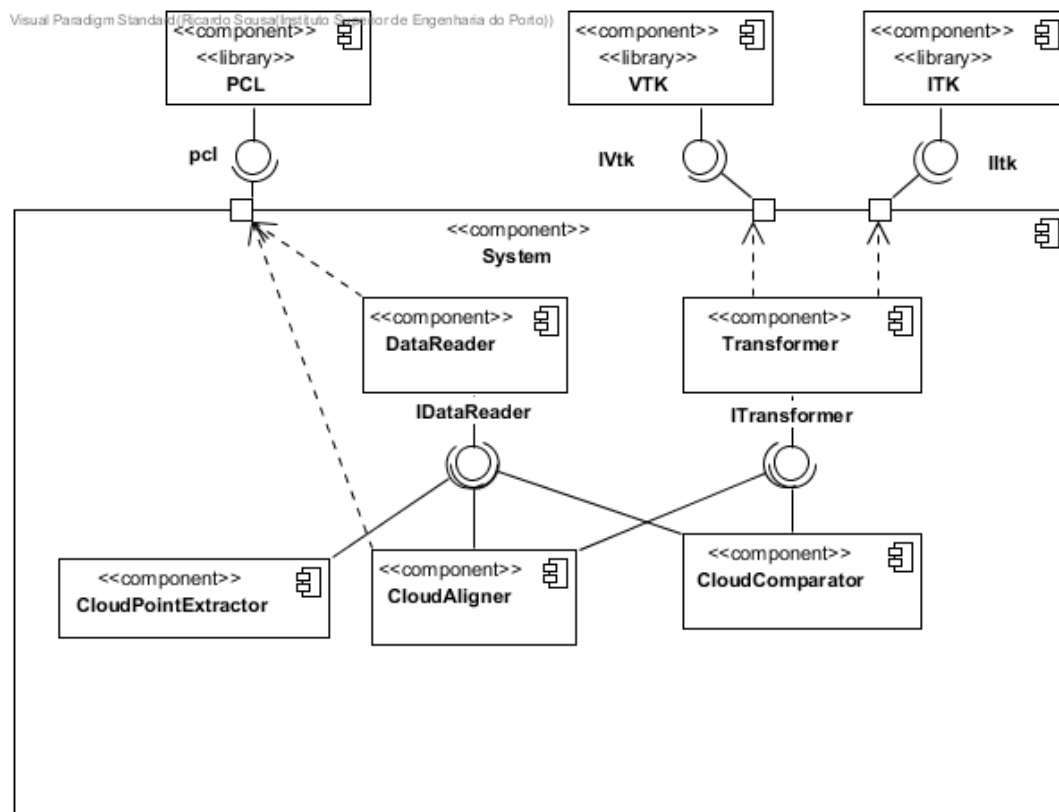


Figura 17 – Arquitetura do sistema

O sistema será constituído por cinco componentes:

- DataReader: Este componente usará as potencialidades da biblioteca PCL para que consiga ler as nuvens de pontos PLY para um objeto do tipo PointCloud legível pelo resto da solução. Este, é um tipo de dados capaz de armazenar coleções de pontos definidos pelas coordenadas  $x, y, z$ .
- CloudAligner: Neste componente serão aplicados os algoritmos de alinhamento das nuvens. Capaz de efetuar a deteção dos pontos de interesse, de *features* e executar os alinhamentos iniciais e refinados com recurso às funcionalidades disponibilizadas pelo PCL.
- CloudComparator: Neste componente, serão aplicados os algoritmos de comparação das nuvens, o cálculo da distância de Hausdorff e o cálculo da distância média para o k-vizinhos-mais-próximos para encontrar qual a nuvem de pontos mais semelhante com a nuvem a ser processada.
- Transformer: Este componente irá utilizar as bibliotecas VTK, ITK e ICP para efetuar as transformações necessárias de uma cabeça deformada na mais semelhante possível com uma cabeça normal, resultando assim um modelo personalizado de uma ortótese craniana para pacientes com Plagiocefalia Posicional.
- CloudPointExtractor: Este componente é capaz de extrair determinados pontos de referência tidos como fulcrais para as medições antropométricas a realizar sobre o

crânio. Estas extrações são efetuadas com recurso a um algoritmo implementado que através da identificação de pontos de relevo, como nariz ou olhos, consegue encontrar os pontos desejados.

## 4.2 Modelos de teste

A solução desenvolvida será testada com dez nuvens de pontos deformadas (Figura 19) criadas a partir de um conjunto de transformações aplicadas a uma nuvem de referência já existente (Nuvem 1 da Figura 19). A partir da nuvem de referência foi também possível criar a nuvem de pontos representativa de uma cabeça normal (Figura 18) que será usada posteriormente como nuvem de referência.

Estas nuvens serviram como base para o processo de implementação tendo sido usadas para aplicar as transformações e comparações necessárias para a obtenção do resultado pretendido de identificação do modelo mais semelhante ao modelo normal.

Tabela 2 – Excerto das transformações aplicadas

|           | N. 1         | N. 2         | N. 3         | N. 4         | N. 5         | N. 6         | N. 7         | N. 8         | N. 9         | N. 10        |
|-----------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
| 1         | 1,272<br>379 | 3,198<br>617 | 1,433<br>115 | 3,842<br>768 | 0,700<br>436 | 7,259<br>274 | 7,921<br>667 | 3,148<br>753 | 8,714<br>992 | 3,698<br>048 |
| 2         | 0,543<br>872 | 2,626<br>881 | 1,278<br>431 | 3,681<br>63  | 2,008<br>554 | 7,106<br>306 | 7,203<br>145 | 3,775<br>224 | 8,350<br>628 | 3,367<br>74  |
| 3         | 0,617<br>988 | 2,556<br>877 | 1,307<br>668 | 3,667<br>075 | 2,021<br>14  | 7,099<br>721 | 7,311<br>76  | 3,413<br>955 | 8,448<br>279 | 3,368<br>414 |
| 4         | 0,576<br>517 | 1,458<br>113 | 1,792<br>927 | 3,813<br>852 | 0,602<br>292 | 7,083<br>277 | 5,546<br>825 | 2,901<br>289 | 7,600<br>91  | 3,136<br>089 |
| 5         | 0,897<br>46  | 0,928<br>452 | 0,709<br>4   | 3,837<br>927 | 3,017<br>243 | 7,042<br>477 | 4,162<br>77  | 3,238<br>173 | 7,086<br>486 | 2,993<br>727 |
| 6         | 0,755<br>777 | 1,171<br>619 | 1,649<br>098 | 3,702<br>118 | 2,720<br>878 | 7,130<br>535 | 4,444<br>28  | 2,820<br>827 | 7,221<br>714 | 2,954<br>62  |
| 7         | 2,373<br>075 | 2,189<br>118 | 2,865<br>614 | 3,256<br>848 | 1,550<br>149 | 7,074<br>628 | 6,015<br>228 | 3,541<br>546 | 6,828<br>37  | 2,488<br>998 |
| 8         | 1,741<br>712 | 3,542<br>636 | 1,611<br>499 | 3,221<br>588 | 2,468<br>273 | 7,349<br>787 | 7,454<br>837 | 3,340<br>563 | 7,452<br>88  | 2,604<br>764 |
| 9         | 1,184<br>987 | 2,011<br>27  | 2,211<br>439 | 3,486<br>109 | 1,642<br>64  | 7,113<br>62  | 5,569<br>476 | 3,511<br>65  | 7,032<br>686 | 2,808<br>564 |
| 10        | 0,867<br>656 | 2,369<br>122 | 1,474<br>368 | 3,714<br>691 | 1,813<br>581 | 7,111<br>452 | 6,469<br>258 | 3,448<br>309 | 7,547<br>55  | 3,082<br>357 |
| ...       | ...          | ...          | ...          | ...          | ...          | ...          | ...          | ...          | ...          | ...          |
| 236<br>87 | 5,227<br>923 | 4,142<br>009 | 5,211<br>605 | 8,691<br>71  | 0,978<br>76  | 1,621<br>728 | 13,37<br>473 | 9,613<br>032 | 5,227<br>923 | 4,142<br>009 |






Figura 18 – Modelo da cabeça normal




Figura 19 – Base de dados de cabeças deformadas

## 4.3 Implementação

### 4.3.1 Downsampling

Em virtude do número elevado de pontos dos modelos 3D de teste Figura 20, foi necessário reduzir o número de vértices das nuvens, sem contudo perder informações importantes para o problema, uma vez que a quantidade de pontos das nuvens originais não é a ideal para a aplicação de algoritmos com elevada complexidade computacional como são os algoritmos de transformação, tais como, o algoritmo ICP.




Figura 20 - Nuvem de pontos original (62711 pontos)

Para efetuar a redução de pontos da nuvem foi criada uma grelha Voxel sobre a nuvem de pontos pretendida, onde os pontos são agrupados em voxels, seguidamente, os pontos de cada Voxel são aproximados para o seu centroíde dando-se assim a redução do número de pontos (Point Cloud Library, Downsampling a PointCloud using a VoxelGrid filter, 2018).




Figura 21 – Representação da nuvem constituída por um conjunto de voxels (52082 voxels)

Esta abordagem é particularmente eficaz quando usada sobre modelos 3D uma vez que representa com maior precisão a superfície subjacente. A Figura 22 correspondente ao *downsampling* da cabeça apresentada na Figura 20, nela é possível verificar que se conseguiu uma redução de cerca de 90% dos pontos mantendo ainda assim a forma original da cabeça.




Figura 22 – Nuvem de pontos reduzida (6569 pontos)

#### 4.3.2 Smoothing

As irregularidades do modelo e as características faciais da cabeça poderiam induzir erros nos resultados finais uma vez que a comparação é feita tendo em conta toda a nuvem de pontos, incluindo as características faciais, características essas que se consideram irrelevantes para o formato da cabeça.

De modo a reduzir o ruído de informação e descartar as características faciais, foi elaborado um alisamento do modelo utilizando o método de reconstrução de superfícies *Moving Least Squares* (MLS) conservando ainda assim as principais características da cabeça deformada, pois, o número de pontos não é reduzido. A Figura 23 apresenta a cabeça da Figura 22 após o alisamento das características faciais.




Figura 23 – Nuvem de pontos alisada (6569 pontos)

#### 4.3.3 Alinhamento das nuvens

Durante o processo de comparação das diferentes nuvens de pontos, uma das principais barreiras que surgiu foi o facto de as diferentes nuvens de pontos não estarem alinhadas, isto é, as nuvens de pontos tinham diferentes orientações e rotações, fazendo assim com que fosse impossível efetuar comparações, uma vez que existe a necessidade das cabeças se encontrarem igualmente orientadas no plano para que as comparações sejam corretas.

Para resolver este problema foi necessário implementar um mecanismo de alinhamento automático que, com base nas características principais de uma cabeça, *Features*, efetue o alinhamento.

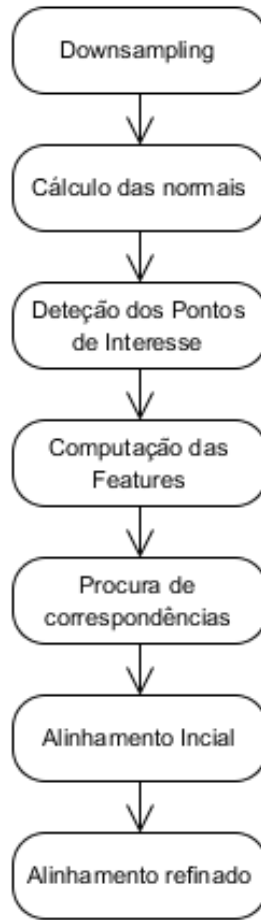


Figura 24 – Processo de alinhamento

- **Cálculo das normais da superfície**

As normais de uma superfície são linhas perpendiculares à superfície num determinado ponto. Dado que os modelos a trabalhar são nuvens de pontos, foram estimadas as normais para cada um desses pontos. O método usado passa pela análise dos autovalores e autovetores da matriz de covariância criada a partir dos vizinhos mais próximos do ponto em questão. Para cada ponto  $p_i$  é definida a matriz de covariância  $C$ :

$$C = \frac{1}{k} \sum_{i=1}^k (p_i - \bar{p})(p_i - \bar{p})^T, \quad C \vec{v}_j = \lambda_j \vec{v}_j, \quad j \in \{0, 1, 2\} \quad (9)$$

Onde,  $k$  é o número de pontos considerados na vizinhança de  $p_i$ ,  $\bar{p}$  representa o centroíde 3D dos vizinhos mais próximos,  $\lambda_j$  é o  $j$ -ésimo autovalor da matriz de covariância e  $\vec{v}_j$  o  $j$ -ésimo autovetor (Point Cloud Library, Estimating Surface Normals in a PointCloud, 2018). Este método encontra-se já implementado na biblioteca PCL, tendo sido usada esta mesma implementação.

- **Deteção dos Pontos de Interesse**

Um aspeto importante para o correto alinhamento das nuvens de pontos era perceber quais os pontos de referência pelos quais o alinhamento deveria ser feito, além disso, a computação de *Features* em nuvens de pontos 3D necessita de ser feita num pequeno conjunto de pontos, sendo, por isso, naturalmente, baseada nestes Pontos de Interesse.

Para obter os resultados desejados foi usado o *Intrinsic Shape Signatures 3D Keypoint Detector* sendo esse reconhecido como o método mais eficaz nesta deteção (Filipe & Alexandre, 2013). Este método utiliza a magnitude do menor autovalor, de modo a incluir apenas os pontos com grande variação em cada uma das principais direções, e o rácio entre dois autovalores sucessivos excluindo os pontos que se estendem ao longo da mesma direção (Filipe & Alexandre, 2013).




Figura 25 – Representação dos Pontos de Interesse (a preto), sobre a nuvem de pontos original (a cinzento)

De notar que, no exemplo ilustrado pela Figura 25, foram detetados 1317 Pontos de Interesse numa nuvem com 6569 pontos, obtendo assim a redução necessária para a computação das *Features*.

- **Computação de *Features***

Para a computação das *features* da nuvem de pontos usando o PFHEstimation implementado pela PCL, foi necessário recorrer à criação da árvore k-dimensional da nuvem de pontos pretendida. Esta árvore, sendo uma estrutura de dados binária cuja principal característica é a eficiência na pesquisa, tem o objetivo de servir como método de pesquisa para a estimação do PFH. As normais da superfície e os pontos de interesse encontrados serviram, também, como ponto de entrada para esta estimação, uma vez que a mesma ocorre apenas sobre os pontos de interesse especificados.

- **Procura de correspondências**

Construindo uma árvore K-dimensional é possível efetuar pesquisas pelos vizinhos mais próximos fornecendo os PFH *descriptors*, encontrados durante a computação das *features*, da nuvem de pontos base e da nuvem de pontos a alinhar. Este tipo de pesquisa usando este tipo de estrutura apresenta relativa eficácia, pois, utiliza as propriedades da árvore para eliminar grandes porções do espaço de pesquisa.

- **Alinhamento Inicial**

O objetivo de efetuar um alinhamento inicial é permitir que o algoritmo ICP tenha melhores resultados numa fase mais avançada uma vez que os modelos já se encontram alinhados ainda que de forma algo grosseira. O alinhamento inicial o que faz é uma translação dos modelos de modo que estes fiquem centrados na mesma origem. Este alinhamento é conseguido através do método *Sample Consensus Initial Alignment* (SAC-IA) que pretende combater a elevada complexidade computacional apresentada noutros métodos de alinhamento tendo sido implementado de forma a manter as relações geométricas entre as correspondências sem a necessidade de serem tentadas todas as combinações possíveis (Rusu et al., 2009). É criada uma amostragem contendo um número elevado de possíveis correspondências sendo estas avaliadas e classificadas empregando os seguintes passos (Rusu et al., 2009):

1. Constrói-se uma amostragem com  $s$  pontos a partir da nuvem de pontos  $C$  garantido que as suas distâncias para os restantes pontos são superiores à distância mínima especificada como parâmetro de entrada para este método;
2. Para cada ponto da amostragem é selecionada uma lista de pontos da nuvem  $Q$  cujos histogramas sejam semelhantes. Desta lista é selecionado um ponto aleatório que servirá como ponto de correspondência;
3. Computa-se a transformação definida pelo ponto da amostra e a sua correspondência e uma métrica de erro que servirá para avaliar a qualidade da transformação e consequente alinhamento.




Figura 26 – Nuvem alvo (vermelho) e nuvem a ser alinhada (azul) antes de se iniciar o processo de alinhamento

Os passos acima descritos são repetidos um número fixo de vezes e a transformação que apresentar um erro menor é usada para alinhar as nuvens de pontos.

Matriz 1 - Matriz encontrada, durante o alinhamento inicial, pelo ICP da transformação final a aplicar à nuvem M (nuvem a vermelho) de modo a alinhar com a nuvem S (nuvem a azul).

*Transformação final*

$$= \begin{bmatrix} 0.309939563 & 0.907954931 & 0.282056004 & 0.000000000 \\ -0.621905684 & 0.418005347 & -0.662197173 & 0.000000000 \\ -0.719145834 & 0.0298288502 & 0.694218755 & 0.000000000 \\ 161.116211 & -709.262512 & -7.66882324 & 1.000000000 \end{bmatrix}$$




Figura 27 – Nuvens de pontos após alinhamento inicial

- **Alinhamento refinado**

A última etapa do processo de alinhamento de nuvens de pontos de acordo com as suas principais características passa por um alinhamento refinado usando o algoritmo ICP e tendo como ponto de entrada a nuvem base representada a vermelho na Figura 26, Figura 27 e Figura 28 e a nuvem a ser alinhada representada a azul na Figura 26.

De forma iterativa, o algoritmo ICP procura minimizar as distâncias entre os pontos das duas nuvens de pontos distintas através de transformações rígidas  $T$  entre nuvem  $S$  e a nuvem de referência  $M$  até satisfazer os critérios definidos.

Este algoritmo inicia-se com um alinhamento aleatório das nuvens, contudo, para a obtenção de resultados mais precisos e reduzir o número necessário de iterações, este passo foi substituído pelo alinhamento que foi feito inicialmente usando o SAC-IA.

Matriz 2 – Matriz encontrada, durante o alinhamento refinado, pelo algoritmo ICP da transformação final a aplicar à nuvem M de modo a alinhar a nuvem S

*Transformação final*

$$= \begin{bmatrix} 0.0900515437 & -0.373942643 & 0.221946746 & 0.000000000 \\ 0.0766212717 & -0.365989238 & -0.927459061 & 0.000000000 \\ 0.428053021 & 0.852200091 & -0.300935030 & 0.000000000 \\ -94.9091110 & -404.498810 & 52.3530579 & 1.000000000 \end{bmatrix}$$






Figura 28 – Nuvens de pontos após alinhamento refinado

#### 4.3.4 Comparação das nuvens

Para se encontrar a cabeça mais semelhante à cabeça estudada é necessário efetuar comparações com cada uma das cabeças disponíveis. Foram utilizados dois métodos distintos para efetuar estas comparações: cálculo da distância de Hausdorff aplicada a modelos 3D e cálculo das distâncias médias entre um ponto e o seu vizinho mais próximo na outra nuvem a comparar.

- **Distância de Hausdorff**

Tendo em conta a simplicidade e eficácia da distância de Hausdorff como métrica de comparação de nuvens de pontos, optou-se pela implementação da mesma. No Apêndice B deste documento é possível visualizar o algoritmo responsável por este cálculo.

As tabelas abaixo descritas descrevem as distâncias  $h(A, B)$ ,  $h(B, A)$  e  $H(A, B)$  para cada uma das nuvens de teste comparativamente com a nuvem que representa uma cabeça considerada normal.

Tabela 3 – Resultados do cálculo da Distância de Hausdorff das nuvens antes de serem alinhadas com a nuvem normal

| N        | Normal $\rightarrow$ N ( $h(B, A)$ ) | N ( $h(A, B)$ ) $\rightarrow$ Normal | Distância Hausdorff ( $H(A, B)$ ) |
|----------|--------------------------------------|--------------------------------------|-----------------------------------|
| Nuvem 1  | 1636,20                              | 1669,70                              | 1669,70                           |
| Nuvem 2  | 2056,76                              | 2130,21                              | 2130,21                           |
| Nuvem 3  | 1638,10                              | 1716,12                              | 1716,12                           |
| Nuvem 4  | 1215,73                              | 1253,74                              | 1253,74                           |
| Nuvem 5  | 1906,97                              | 1993,68                              | 1993,68                           |
| Nuvem 6  | 1232,67                              | 1316,99                              | 1316,99                           |
| Nuvem 7  | 2101,06                              | 2132,67                              | 2132,67                           |
| Nuvem 8  | 1677,15                              | 1744,98                              | 1677,15                           |
| Nuvem 9  | 909,58                               | 943,59                               | 943,59                            |
| Nuvem 10 | 540,84                               | 568,37                               | 568,37                            |

Com base nos resultados apresentados na Tabela 3 é possível concluir que antes do alinhamento a nuvem que apresentava uma Distância de Hausdorff menor para o modelo normal era a Nuvem 10 podendo, nesta fase, ser considerada a cabeça mais próxima, no entanto, uma vez que as cabeças se encontram dispersas pelo plano este não é um resultado fiável, para isso, existe a necessidade de uniformizar, alinhando, as nuvens tendo como ponto de referência a nuvem normal.

Tabela 4 – Resultados do cálculo da Distância de Hausdorff das nuvens após um alinhamento inicial para com a nuvem normal

| N        | $N(h(A,B)) \rightarrow \text{Normal}$ | $\text{Normal} \rightarrow N(h(B,A))$ | Distância Hausdorff<br>( $H(A,B)$ ) |
|----------|---------------------------------------|---------------------------------------|-------------------------------------|
| Nuvem 1  | 77,77                                 | 68,23                                 | 77,77                               |
| Nuvem 2  | 100,86                                | 74,02                                 | 100,86                              |
| Nuvem 3  | 115,11                                | 68,21                                 | 115,11                              |
| Nuvem 4  | 113,06                                | 68,85                                 | 113,06                              |
| Nuvem 5  | 89,93                                 | 81,52                                 | 89,93                               |
| Nuvem 6  | 107,84                                | 71,98                                 | 107,84                              |
| Nuvem 7  | 86,18                                 | 67,57                                 | 86,18                               |
| Nuvem 8  | 99,17                                 | 70,89                                 | 99,17                               |
| Nuvem 9  | 99,47                                 | 74,36                                 | 99,47                               |
| Nuvem 10 | 101,54                                | 74,17                                 | 101,54                              |

Os resultados apresentados na Tabela 4 são ilustrativos da importância do processo de alinhamento, podendo-se verificar que o valor das distâncias diminuiram significativamente com um valor médio  $\cong 1444,13$  pontos, sendo que a Nuvem 2 assume um valor mais baixo e, portanto, será a cabeça mais semelhante.

Tabela 5 – Resultados do cálculo da Distância de Hausdorff das nuvens após um alinhamento refinado para com a nuvem normal

| N        | $\text{Normal} \rightarrow N(h(A,B))$ | $N(h(B,A) \rightarrow \text{Normal}$ | Distância Hausdorff<br>( $H(A,B)$ ) |
|----------|---------------------------------------|--------------------------------------|-------------------------------------|
| Nuvem 1  | 52,79                                 | 45,78                                | 45,78                               |
| Nuvem 2  | 62,94                                 | 56,53                                | 56,53                               |
| Nuvem 3  | 67,99                                 | 112,61                               | 112,61                              |
| Nuvem 4  | 63,18                                 | 98,53                                | 98,53                               |
| Nuvem 5  | 58,77                                 | 80,75                                | 80,75                               |
| Nuvem 6  | 62,09                                 | 100,21                               | 100,21                              |
| Nuvem 7  | 51,00                                 | 69,94                                | 69,94                               |
| Nuvem 8  | 63,61                                 | 73,80                                | 73,80                               |
| Nuvem 9  | 72,77                                 | 96,99                                | 96,99                               |
| Nuvem 10 | 62,45                                 | 97,41                                | 97,41                               |

Com base na Tabela 5 é possível verificar que o alinhamento refinado diminui em média 33,83 pontos de distância entre as duas nuvens de pontos sujeitas à comparação. Com isto, destaca-se também que, seguindo dos cálculos da Distância de Hausdorff, a Nuvem 2 será a nuvem mais semelhante à nuvem de pontos usada como referência.

- **Distância média para o vizinho mais próximo (kNN)**

Tendo como base o algoritmo ICP que procura diminuir as distâncias entre pontos e a Distância de Hausdorff, foi criado um método de comparação de nuvens de pontos. Este método para cada ponto  $P_A$  da nuvem  $A$  encontra o ponto  $P_B$  da nuvem  $B$  mais próximo, calcula a distância entre  $P_A$  e  $P_B$  e por último calcula a média das distâncias obtidas. O Apêndice C deste documento revela o algoritmo implementado para este cálculo.

Tabela 6 – Distâncias médias de cada ponto de uma nuvem  $A$  relativamente ao ponto mais próximo da nuvem original

| N        | Distância antes do alinhamento | Distância após alinhamento inicial | Distância após alinhamento refinado |
|----------|--------------------------------|------------------------------------|-------------------------------------|
| Nuvem 1  | 4,04772e+06                    | 860,06                             | 212,20                              |
| Nuvem 2  | 2,40937e+06                    | 1675,3                             | 532,19                              |
| Nuvem 3  | 2,55935e+06                    | 1777,44                            | 917,85                              |
| Nuvem 4  | 3,51887e+06                    | 1750,41                            | 883,58                              |
| Nuvem 5  | 735737                         | 1585,77                            | 402,75                              |
| Nuvem 6  | 4,0573e+06                     | 1166,13                            | 1570,08                             |
| Nuvem 7  | 1,44158e+06                    | 2103,73                            | 789,33                              |
| Nuvem 8  | 1,29783e+06                    | 1015,61                            | 836,46                              |
| Nuvem 9  | 2,65399e+06                    | 1637,54                            | 1438,36                             |
| Nuvem 10 | 2067,69                        | 1786,73                            | 1652,55                             |

De acordo com os resultados obtidos com este método a nuvem mais próxima da nuvem normal é a nuvem 1, ambas representadas na figura 31.




Figura 29 – Nuvem 1 classificada como a mais semelhante com à nuvem de referência (azul e verde representa os pontos mais semelhantes enquanto que amarelo e vermelho os mais distantes)

Este método embora simples pode apresentar-se como pouco eficaz e sujeito a erros uma vez que o ponto mais próximo poderá, mesmo após alinhamento, não corresponder a um ponto desejável na nuvem a comparar.

#### 4.3.5 Detecção das medidas antropométricas requeridas para a modelação da ortótese

De modo a facilitar as medições antropométricas cranianas foi necessário identificar alguns pontos de referência na nuvem de pontos tais como tragions, sellions, o ponto superior da cabeça e o ponto atrás da nuca representados na Figura 30.




Figura 30 – Pontos de referência para as medidas antropométricas usadas na modelação da ortótese

O ponto superior da cabeça foi detetado como o ponto com o valor máximo da coordenada no eixo do Y.

O sellion, depressão mais profunda dos ossos nasais (Lazovic et al., 2015), foi conseguido encontrando o ponto médio entre os pontos representativos dos cantos dos olhos, estes foram obtidos detetando os dois pontos mais próximos ao ponto médio total da nuvem de pontos.

A deteção dos Tragions, pontos cefalométricos imediatamente acima da relevância conhecida como tragus da orelha (Farlex Partner Medical Dictionary, 2012), foi conseguida detetando os tragus da orelha, estas relevâncias traduzem-se nos pontos localizados nas extremidades do eixo do X. Conhecendo os tragus foram procurados os pontos imediatamente acima, ou seja, com um valor de Y superior e com o valor mínimo de X, deste modo encontrou-se a concavidade acima do tragus que representa os tragions da orelha.

O ponto traseiro representativo da nuca da cabeça foi conseguido detetando o ponto oposto ao sellion.

Estes pontos de referência foram posteriormente tidos em conta nos cálculos das dimensões cranianas que se traduzem nas medidas antropométricas.

De modo a conseguir obter estas medidas foi necessário dividir o modelo da cabeça em 10 planos iguais, sendo o plano 0 o plano traçado pelo sellion e cantos dos olhos e o plano 10 o plano traçado no topo da cabeça. Para medir a circunferência da cabeça foi utilizado o plano 3 somando a distância entre cada um desses pontos:

$$\text{Circunferência} = \sum \sqrt{(x_1 - x_2)^2 + (z_1 - z_2)^2} \quad (10)$$

Com recurso ao plano 3 foi também calculada a largura e a altura da cabeça, sendo que a largura corresponde à diferença entre o máximo e o mínimo valor de  $x$ , enquanto que a altura é obtida através da diferença entre o valor máximo e mínimo de  $z$ . O índice cefálico é dado pela relação entre a largura e a altura da cabeça. Por último, foi possível calcular a diferença diagonal, isto é, a diferença entre as duas diagonais possíveis de traçar tendo em conta os valores máximos e mínimos de  $x$  e  $z$ .




Figura 31 – Representação do Plano 3 a vermelho

Tabela 7 – Medidas antropométricas

|          | Circunferência<br>craniana<br>(mm) | Largura<br>(mm) | Altura (mm) | Índice<br>cefálico (%) | Diferença<br>diagonal<br>(mm) |
|----------|------------------------------------|-----------------|-------------|------------------------|-------------------------------|
| Nuvem 1  | 445.8                              | 120.6           | 152.8       | 78,9                   | 5.2                           |
| Nuvem 2  | 477.9                              | 119.9           | 150.7       | 79,5                   | 8                             |
| Nuvem 3  | 437.7                              | 117.0           | 143.6       | 81,4                   | 3.9                           |
| Nuvem 4  | 430.8                              | 120.9           | 147.2       | 82,1                   | 10.3                          |
| Nuvem 5  | 417.9                              | 117.6           | 145.4       | 80,9                   | 8.9                           |
| Nuvem 6  | 426.9                              | 121.3           | 148.3       | 81,8                   | 2.8                           |
| Nuvem 7  | 594.6                              | 120             | 142.3       | 84,3                   | 10.8                          |
| Nuvem 8  | 781.7                              | 119.5           | 143.4       | 83,3                   | 22.9                          |
| Nuvem 9  | 436.2                              | 116.4           | 149.6       | 77,8                   | 10.4                          |
| Nuvem 10 | 548.6                              | 152.2           | 189.7       | 80,2                   | 2.5                           |



## 5 Avaliação

A avaliação dos resultados obtidos é uma parte vital no processo de desenvolvimento de qualquer projeto pois permite perceber, por exemplo, se este responde aos requisitos que pretende resolver. Assim sendo, é de particular importância que antes da avaliação em si, sejam definidas medidas e métodos de avaliação precisos que avaliem de forma qualitativa o projeto.

Para este projeto, o método de avaliação dos resultados obtidos das comparações de semelhança foi realizado tendo por base as transformações realizadas sobre as nuvens de pontos.

Como referido na secção 4.2, os dados para teste da solução desenvolvida foram obtidos através de diversas transformações sobre uma nuvem de pontos de referência originando assim o conjunto de teste exibido na Figura 18 e Figura 19. A Tabela 2 representa um excerto das transformações aplicadas. Calculando a média das várias transformações aplicadas sobre a nuvem de pontos de referência é possível ter uma ordem de grandeza das transformações aplicadas sobre cada nuvem e consequentemente determinar a mais semelhante.

Tabela 8 – Transformações médias aplicadas

| Nuvem    | Transformação média |
|----------|---------------------|
| Nuvem 1  | 1.923605242         |
| Nuvem 2  | 2.100002723         |
| Nuvem 7  | 2.299598366         |
| Nuvem 8  | 3.04106765          |
| Nuvem 5  | 3.137961496         |
| Nuvem 3  | 3.289652915         |
| Nuvem 4  | 3.457589966         |
| Nuvem 10 | 4.373202704         |
| Nuvem 6  | 7.623099876         |
| Nuvem 9  | 7.963294736         |

Tendo acesso aos valores da transformação média é possível ordenar as nuvens por semelhança (Tabela 8) e comparar os resultados obtidos com o cálculo da Distância de Hausdorff e com o cálculo das distâncias médias dos vizinhos mais próximos (Tabela 9)



Tabela 9 – Comparação dos resultados de semelhança de nuvens

|    | Transformações médias | Distância de Hausdorff (DH) | Distância média para kNN (DkNN) |
|----|-----------------------|-----------------------------|---------------------------------|
| 1  | Nuvem 1               | Nuvem 1                     | Nuvem 1                         |
| 2  | Nuvem 2               | Nuvem 2                     | Nuvem 5                         |
| 3  | Nuvem 7               | Nuvem 7                     | Nuvem 2                         |
| 4  | Nuvem 8               | Nuvem 8                     | Nuvem 7                         |
| 5  | Nuvem 5               | Nuvem 5                     | Nuvem 8                         |
| 6  | Nuvem 3               | Nuvem 9                     | Nuvem 4                         |
| 7  | Nuvem 4               | Nuvem 10                    | Nuvem 3                         |
| 8  | Nuvem 10              | Nuvem 4                     | Nuvem 9                         |
| 9  | Nuvem 6               | Nuvem 6                     | Nuvem 6                         |
| 10 | Nuvem 9               | Nuvem 3                     | Nuvem 10                        |

Para interpretação dos resultados comparados na Tabela 9 foi calculado o coeficiente de correlação de postos de Spearman,  $F(\sigma, \tau)$ , e o coeficiente de correlação de postos de Kendall,  $K(\sigma, \tau)$ .

Sendo  $[n] = \{1, \dots, n\}$  o conjunto total de elemento,  $S_n$  o conjunto de permutações de  $[n]$  e para  $\sigma \in S_n$ ,  $\sigma(i)$  representa a posição do elemento  $i$ , temos:

$$F(\sigma) = \sum_i |i - \sigma(i)| \quad (11)$$

o coeficiente de correlação de postos de Spearman mede o deslocamento total de cada elemento da tabela sendo que quanto menor for este valor, maior será a semelhança entre as duas tabelas, e:

$$K(\sigma) = \sum_{(i,j): i > j} [\sigma(i) < \sigma(j)] \quad (12)$$

o coeficiente de correlação de postos de Kendall que mede o número total de inversões em pares classificativos das relações entre as duas tabelas a comparar. Este valor varia entre 0 e 1, onde 0 indica que não existe nenhum tipo de relação entre as tabelas e 1 uma relação perfeita (Kumar & Vassilvitskii, 2010).

Representando a coluna Transformações médias da Tabela 9 como um vetor  $[1, \dots, 10]$ , em que [Nuvem 1 = 1, Nuvem 2 = 2, Nuvem 7 = 3, ... Nuvem 9 = 10], temos:

$$F(\sigma)_{DH} = |1 - 1| + |2 - 2| + |3 - 3| + |4 - 4| + |5 - 5| + |6 - 10| + |7 - 8| + |8 - 7| + |9 - 9| + |10 - 6| = 10 \quad (13)$$

$$F(\sigma)_{DkNN} = |1 - 1| + |2 - 5| + |3 - 2| + |4 - 3| + |5 - 4| + |6 - 7| + |7 - 6| + |8 - 10| + |9 - 9| + |10 - 8| = 13 \quad (14)$$

Sendo o coeficiente de correlação de pontos de Spearman inferior para os resultados apresentados das comparações usando a Distância de Hausdorff é possível concluir que,

segundo esta métrica, este método de comparação é mais fidedigno. Partindo do mesmo pressuposto relativamente à representação do conjunto de dados da coluna de Transformações médias da Tabela 9 onde [Nuvem 1 = 1, Nuvem 2 = 2, Nuvem 7 = 3,... Nuvem 9 = 10] tem-se o coeficiente da correlação de postos de Kendall. Simplificando, este coeficiente pode ser calculado através da relação entre o número de pares concordantes com o número de pares discordantes, dado por:

$$K = \frac{C - D}{C + D} \quad (15)$$

Onde  $C$  é o número de pares concordantes e  $D$  o número de pares discordantes.

Os pares concordantes são todos os pares maiores abaixo de  $\sigma(i, j)$  enquanto que os pares discordantes são os pares menores que  $\sigma(i, j)$  que se encontram abaixo dos mesmos (Nelsen, 2002).

Para este cálculo pode-se recorrer a uma tabela adicional que deverá estar ordenada de forma ascendente de acordo com os valores da coluna de Transformações médias, deste modo:

Tabela 10 – Pares concordantes e discordantes para o cálculo do coeficiente de correlação de Kendall para as comparações através da Distância de Hausdorff

| Transformações médias | Distância de Hausdorff | Pares Concordantes | Pares Discordantes |
|-----------------------|------------------------|--------------------|--------------------|
| Nuvem 1               | Nuvem 1                | 9                  | 0                  |
| Nuvem 2               | Nuvem 2                | 8                  | 0                  |
| Nuvem 7               | Nuvem 7                | 7                  | 0                  |
| Nuvem 8               | Nuvem 8                | 5                  | 1                  |
| Nuvem 5               | Nuvem 5                | 5                  | 0                  |
| Nuvem 3               | Nuvem 9                | 4                  | 0                  |
| Nuvem 4               | Nuvem 10               | 3                  | 1                  |
| Nuvem 10              | Nuvem 4                | 1                  | 0                  |
| Nuvem 6               | Nuvem 6                | 0                  | 1                  |
| Nuvem 9               | Nuvem 3                | 0                  | 0                  |
| Total                 |                        | $C = 42$           | $D = 3$            |

Tabela 11 - Pares concordantes e discordantes para o cálculo do coeficiente de correlação de Kendall para as comparações através da Distância dos kNN

| <b>Transformações médias</b> | <b>Distância kNN</b> | <b>Pares Concordantes</b> | <b>Pares Discordantes</b> |
|------------------------------|----------------------|---------------------------|---------------------------|
| Nuvem 1                      | Nuvem 1              | 9                         | 0                         |
| Nuvem 2                      | Nuvem 5              | 8                         | 1                         |
| Nuvem 7                      | Nuvem 2              | 7                         | 0                         |
| Nuvem 8                      | Nuvem 7              | 6                         | 0                         |
| Nuvem 5                      | Nuvem 8              | 4                         | 1                         |
| Nuvem 3                      | Nuvem 4              | 3                         | 1                         |
| Nuvem 4                      | Nuvem 3              | 3                         | 0                         |
| Nuvem 10                     | Nuvem 9              | 1                         | 1                         |
| Nuvem 6                      | Nuvem 6              | 1                         | 0                         |
| Nuvem 9                      | Nuvem 10             | 0                         | 0                         |
| Total                        |                      | $C = 41$                  | $D = 4$                   |

Com base na Tabela 10 e

Tabela 11, é possível proceder ao cálculo do coeficiente de correlação de Kendall, onde para a Distância de Hausdorff temos:

$$K(\sigma)_{DH} = \frac{42 - 3}{42 + 3} = \frac{39}{45} \cong 0,867 \quad (16)$$

e para as comparações baseadas no kNN:

$$K(\sigma)_{DkNN} = \frac{41 - 4}{41 + 4} = \frac{37}{45} \cong 0,822 \quad (17)$$

Sendo assim é possível concluir que apresentando um coeficiente de  $\cong 0,867$ , as comparações baseadas na Distância de Hausdorff apresentam uma maior relação com os resultados reais obtidos pelas transformações médias aplicadas sendo, portanto, uma forma mais fiável de efetuar comparações sobre nuvens de pontos relativamente ao resultado médio da distância para o k-vizinho-mais-próximo.

## 6 Conclusões

Com a acentuação dos avanços tecnológicos tem-se vindo a verificar uma expansão da sua utilização em diversas áreas com o objetivo de simplificar ou substituir tarefas manuais de elevada importância que se encontram sujeitas a erro humano. Estes avanços, além de aperfeiçoarem tecnologias existentes, conduzem também à criação de novas tecnologias com grande utilidade tanto para o utilizador comum como para tarefas que requerem um elevado nível de precisão e uma reduzida probabilidade de erro, tornando assim processos complexos e com um consumo de tempo elevado em processos automáticos, ágeis e simples de serem executados.

Com esta dissertação pretendia-se colaborar na fase inicial da criação de um processo automático de uma tarefa que atualmente é totalmente manual e sujeita a erros: modelação de ortóteses cranianas para pacientes com Plagiocefalia Posicional, uma condição associada a deformações no crânio de crianças recém-nascidas. Para isto foi necessário preparar e trabalhar nuvens de pontos existentes, e representativas de cabeças com esta condição, de modo que facilmente possam vir a ser utilizadas numa fase posterior do processo de criação deste mecanismo de modelação automático de ortóteses. Os objetivos desta dissertação eram o de conseguir identificar a nuvem de pontos mais semelhante a uma nuvem de pontos de referência e extrair a posição de pontos-chave para as medições antropométricas da cabeça do recém-nascido.

Inicialmente as nuvens encontravam-se em diferentes posições no espaço, pelo que grande parte do trabalho desenvolvido foi alinhar as nuvens de pontos tendo em conta pontos-chave de alinhamento como, por exemplo, os olhos, a boca e as orelhas, ou seja, foi necessário identificar estes pontos em cada uma das cabeças e efetuar a aproximação das mesmas características com as outras nuvens, de modo a ficarem todas com a mesma posição e orientação no espaço. Este passo foi relativamente importante tendo em conta que a comparação da semelhança das nuvens foi baseada nas distâncias entre os pontos das nuvens a comparar e para que esta comparação se revelasse eficaz era necessário as nuvens estarem no mesmo referencial e sobre o mesmo ponto de origem.

Com as nuvens alinhadas, foi possível aplicar a computação da Distância de Hausdorff e a distância média para o kNN de modo a encontrar a nuvem de pontos mais semelhante. Estes dois métodos de comparação de nuvens de pontos revelaram resultados satisfatórios apresentando um Coeficiente de Kendall de  $\cong 0,867$  e  $\cong 0,822$ , respetivamente. A extração

de pontos antropométricos de referência foi também conseguida com sucesso tendo compreendido um estudo prévio acerca dos pontos a detetar e de como seria possível, com base noutros pontos, encontrar os pretendidos. Esta deteção foi conseguida utilizando os pontos com maior relevo para facilmente identificar os pontos restantes.

Em suma, foi um trabalho útil para a criação do mecanismo de modelação automático de ortóteses uma vez que atingiu os resultados previstos de modo satisfatório tendo sido ultrapassado um dos pontos fulcrais para este processo, a identificação da nuvem de pontos de uma cabeça normal mais semelhante à cabeça deformada para se utilizar como base ao modelo da ortótese a fabricar.

## 6.1 Limitações

Uma das principais limitações prendeu-se com o facto de existir um número reduzido de nuvens de pontos, e das existentes serem todas derivadas da mesma nuvem. Os resultados obtidos com esta amostra inicial embora promissores não são estatisticamente relevantes, no entanto servem como prova de conceito da abordagem desenvolvida.

## 6.2 Trabalho futuro

Como forma de melhorar e aprimorar o método de alinhamento das nuvens de pontos, poderá futuramente ser efetuado um estudo e uma correção dos parâmetros de entrada dos diversos algoritmos utilizados, tais como o número de iterações e os *thresholds* de pesquisa. Estas correções poderão permitir que sejam obtidos resultados ainda mais exatos.

Além disso, com uma base de dados de casos reais de PP de maior dimensão, poderão ser testadas técnicas de *Data Mining* para identificar a cabeça normal mais semelhante a uma cabeça com PP e comparados os resultados com a abordagem aqui desenvolvida.

Com esta fase do processo concluída é possível avançar para as próximas fases do projeto de criação automática da ortótese craniana. As próximas fases poderão usar o modelo identificado como o mais semelhante e as medidas antropométricas extraídas dos pontos de referência para construir a ortótese. Desta forma, é esperado que a aplicação da nova ortótese personalizada e instrumentada evite as principais complicações associadas ao tratamento tradicional, nomeadamente lesões de pele, perda de cabelo e desconforto.

## Referências

- Alliez, P., Ucelli, G., Gotsman, C., & Attene, M. (2008). Recent Advances in Remeshing of Surfaces. In *Shape Analysis and Structuring. Mathematics and Visualization* (pp. 53-82). Springer, Berlin, Heidelberg.
- Barquet, A. P., Cunha, V. P., Oliveira, M. G., & Rozenfeld, H. (2011). Business Model Elements for Product-Service System. In *Functional Thinking for Value Creation* (pp. 332-337). Berlin, Heidelberg: Springer.
- Basdogan, C., & Oztireli, A. C. (2008). A new feature-based method for robust and efficient rigid-body registration of overlapping point clouds. *The Visual Computer*, 24(7-9), 679-688.
- Bentley, J. L. (1975, 1975). Multidimensional binary search trees used for associative searching. *Communications of the ACM*, 18(9), 509-517.
- Besl, P. J., & McKay, N. D. (1992). A Method of Registration of 3-D Shapes. *Pattern Analysis and Machine Intelligence*, 14 (2), 239-256.
- Bronshtein, A. (2017). *Train/Test Split and Cross Validation in Python*. Retrieved 02 2018, from <https://towardsdatascience.com/train-test-split-and-cross-validation-in-python-80b61beca4b6>
- Chen, Y., & Medioni, G. (1991). Object modelling by registration of multiple range images. *Proceedings. 1991 IEEE International Conference on Robotics and Automation*, 10(3), 145-155.
- Clarren, S. K. (1981). Plagiocephaly and torticollis: etiology, natural history, and helmet treatment. *The Journal of Pediatrics*, 1, 92-95.
- Cooperman, D. R., & Karmel-Ross, K. (1997). The Differential Diagnosis of Torticollis in Children. *Physical & Occupational Therapy In Pediatrics*, 17 (2), 1-11.

- Dyshkant, N. (2013). Comparison of Point Clouds Acquired by 3D Scanner. *Lecture Notes in Computer Science*, 7749, 47-58.
- Farlex Partner Medical Dictionary. (2012). *Tragion*. Retrieved Setembro 2018, from <https://medical-dictionary.thefreedictionary.com/tragion>
- Filipe, S., & Alexandre, L. A. (2013). *A Comparative Evaluation of 3D Keypoint Detectors*. Covilhã: Department of Computer Science, University of Beira Interior.
- Friedman, J. H., Bentley, J. L., & Finkel, R. A. (1977). An Algorithm for Finding Best Matches in Logarithmic Expected Time. *ACM Transactions on Mathematical Software*, 3(3), 209-226.
- Gao, J. (n.d.). Clustering Lecture 1: Basics. State University of New York at Buffalo.
- Grimmer, R., Eskofier, B., Schlarb, H., & Hornegger, J. (2011). Comparison and classification of 3D objects surface point clouds on the example of feet. *Machine Vision and Applications*, 22(2), 235-243.
- Hartigan, J. A. (1975). *Clustering Algorithms*. New York: John Wiley & Sons, Inc.
- He, Y., Liang, B., Yang, J., Shunzhi, L., & He, J. (2017). An Iterative Closest Points Algorithm for Registration of 3D Laser Scanner Point Clouds with Geometric Features. In *Sensors* 17(8) (p. 1862). China.
- Huang, H., Cui, C., Chen, L., Liu, Q., & Wang, J. (2012). Grid interpolation algorithm based on nearest neighbor fast search. *Earth Science Informatics*, 3-4(5), 181-187.
- Ifflaender, S., Rüdiger, M., Koch, A., & Burkhardt, W. (2013). Three-Dimensional Digital Capture of Head Size in Neonates – A Method Evaluation. *PLOS One*, 8 (4).
- Insight Software Consortium. (2018). *ITK - Segmentation & Registration Toolkit*. Retrieved Fevereiro 2018, from <https://itk.org/ITK/project/about.html>
- Kelly, K. M., Littlefield, T. R., Pomatto, J. K., Manwaring, K. H., & Beals, P. S. (1999). Cranial Growth Unrestricted during. *Pediatric Neurosurgery*, 30, 193-199.
- Kitware. (2018). *VTK - The Visualization Toolkit*. Retrieved Fevereiro 2018, from <https://www.vtk.org/overview/>
- Koen, P., Ajamian, G., Burkart, R., Clamen, A., Davidson, J., D'Amore, R., . . . Wagner, K. (2001). Providing Clarity and A Common Language to the “Fuzzy Front End”. *Research - Technology Management*, 44(2), 46-55.
- Koen, P., Bertels, H. M., & Kleinschmidt, E. J. (2014). Managing the Front End of Innovation Part-I Results From a Three-Year Study. *Research Technology Management*, 57(3), 34-43.



- Kumar, R., & Vassilvitskii, S. (2010). Generalized Distances between Rankings. In *WWW '10 Proceedings of the 19th international conference on World wide web* (pp. 571-580). Raleigh, North Carolina, USA.
- Lazovic, G. D., Daniel, R. K., Jnosevic, L. B., Kosanovic, R. M., Colic, M. M., & Kosins, A. M. (2015). Rhinoplasty: The Nasal Bones - Anatomy and Analysis. *Aesthetic Surgery Journal*, 35(3), 255-263.
- Li, Y., Liu, N., Zhang, H. H., Yu, J., & Sun, S. (2017). Using Fuzzy Front End Theory on the New Product Development and Innovation. Singapore, Singapore: IEEE.
- Manning, C. D., Raghavan, P., & Schütze, H. (2008). *Introduction to Information Retrival*. Cambridge University Press.
- Moss, D. (1997). Nonsurgical, nonorthotic treatment of occipital plagiocephaly: what is the natural history of the misshapen neonatal head? *J. Neurosurg.*, 87, 667-670.
- Mullin, M., & Sukthankar, R. (2000). Complete Cross-Validation for Nearest Neighbor Classifiers. In *Proceedings of the Seventeenth International Conference on Machine Learning* (pp. 639-646). San Francisco, CA, USA: Morgan Kaufmann Publishers Inc.
- Nelsen, R. B. (2002). Kendall tau metric. In *Encyclopedia of Mathematics*.
- Nicola, S. (2017). Análise de Valor de Negócio, aula 1.
- O'Broin, E., Allcutt, D., & Earley, M. J. (1999). Posterior plagiocephaly: proactive conservative management. *British Journal of Plastic Surgery*, 52, 18-23.
- Oniga, E., & Chirila, C. (2013). Hausdorff Distance for the Differences Calculation Between 3D Surfaces. *RevCAD*, 15, 193-202.
- Plank, L. H., Giavedoni, B., Lombardo, J. R., Geil, M. D., & Reisner, A. (2006). Comparison of Infant Head Shape Changes in Deformational Plagiocephaly Following Treatment With a Cranial Remolding Orthosis Using a Noninvasive Laser Shape Digitizer. *J Craniofac Surg*, 17, 1084-1091.
- Point Cloud Library. (2018). *Downsampling a PointCloud using a VoxelGrid filter*. Retrieved 07 2018, from [http://pointclouds.org/documentation/tutorials/voxel\\_grid.php](http://pointclouds.org/documentation/tutorials/voxel_grid.php)
- Point Cloud Library. (2018). *Estimating Surface Normals in a PointCloud*. Retrieved 2018, from [http://pointclouds.org/documentation/tutorials/normal\\_estimation.php](http://pointclouds.org/documentation/tutorials/normal_estimation.php)
- Point Cloud Library. (2018). *Module Octree*. Retrieved 09 2018, from [http://docs.pointclouds.org/1.8.1/group\\_\\_octree.html](http://docs.pointclouds.org/1.8.1/group__octree.html)
- Point Cloud Libray. (2018). *Point Feature Histograms (PFH) descriptors*. Retrieved 2018, from [http://pointclouds.org/documentation/tutorials/pfh\\_estimation.php](http://pointclouds.org/documentation/tutorials/pfh_estimation.php)

- Robinson, S., & Proctor, M. (2009). Diagnosis and management of deformational plagiocephaly. *J. Neurosurg. Pediatrics*, 3, 284-295.
- Rogers, G. F., Miller, J., & Mulliken, J. B. (2008). Comparison of a Modifiable Cranial Cup versus Repositioning and Cervical Stretching for the Early Correction of Deformational Posterior Plagiocephaly. *Plastic and Reconstructive Surgery Journal*, 941-947.
- Rusinkiewicz, S., & Levoy, M. (2001). Efficient variants of the ICP algorithm. *Proceedings Third International Conference on 3-D Digital Imaging and Modeling*, (pp. 145-152). Quebec City, Quebec, Canada, Canada. doi:10.1109/IM.2001.924423
- Rusu, R. B., & Cousins, S. (2011). 3D is here: Point Cloud Library (PCL). *IEEE International Conference on Robotics and Automation (ICRA)*.
- Rusu, R. B., Blodow, N., & Beetz, M. (2009). Fast Point Feature Histograms (FPFH) for 3D registration. Kobe, Japan: IEEE.
- Schwenn, S. R., Sandifer, A. T., & Price, J. W. (2002). *Patent No. US6428494 B1*.
- Shouval, R., Bondi, O., Mishan, H., Shimoni, A., Unger, R., & Nagler, A. (2014). Application of machine learning algorithms for clinical predictive modeling: a data-mining approach in SCT. *Bone Marrow Transplantation*, 49, 332-337.
- Smistad, E., Falch, T. L., Bozorgi, M., Elster, A. C., & Lindseth, F. (2015). Medical image segmentation on GPUs - A comprehensive review. *Medical Image Analysis*, 20(1), 1-18.
- Teichgraeber, J. F., Seymour-Dempsey, K., Baumgartner, J. E., Xia, J. J., Waller, A. L., & Gateno, J. (2004). Molding Helmet Therapy in the Treatment of. *Journal of Craniofacial Surgery*, 15, 118-123.
- Trevino, A. (2016). *Introduction to K-means Clustering*. Retrieved 02 2018, from <https://www.datascience.com/blog/k-means-clustering>
- Visa, S., Ramsay, B., Ralescu, A., & van der Knaap, E. (2011). Confusion Matrix-based Feature Selection.
- Wikipedia. (2018). *k-means clustering*. Retrieved 02 2018, from [https://en.wikipedia.org/wiki/K-means\\_clustering](https://en.wikipedia.org/wiki/K-means_clustering)
- Wikipedia. (2018). *k-nearest neighbors algorithm*. Retrieved 02 2018, from [https://en.wikipedia.org/wiki/K-nearest\\_neighbors\\_algorithm#Algorithm](https://en.wikipedia.org/wiki/K-nearest_neighbors_algorithm#Algorithm)
- Zhang, D., Hr, F., Han, S., Zou, L., Wu, Y., & Chen, Y. (2017). An efficient approach to directly compute the exact Hausdorff distance for 3D point sets. *Integrated Computer-Aided Engineering*, 24 (3), 261-277.

## **Apêndices**



## Apêndice A – Abordagem existente para tratamento de doentes com PP utilizando modelos 3D

Num período de um ano, foram diagnosticadas duzentas e vinte e quatro crianças com PP que serviram como base para o estudo “Comparison of Infant Head Shape Changes in Deformational Plagiocephaly Following Treatment With a Cranial Remolding Orthosis Using a Noninvasive Laser Shape Digitizer” de Plank et. al. em 2006, sendo que duzentas e sete foram submetidas a tratamento com ortótese e as restantes dezassete, por rejeição das famílias ao tratamento, serviram como grupo de controlo.

Para este estudo foi utilizado um *scanner* que capturou um modelo 3D da cabeça das crianças com uma exatidão na ordem dos 0.5 mm que foi utilizado para a criação da ortótese craniana para cada um dos pacientes do grupo de tratamento. Durante quatro meses seguintes, os pacientes realizaram novos *scans* com uma periodicidade de duas semanas de forma a garantir que se encontravam dentro dos requisitos necessários para o estudo, além disso, estes *scans* foram utilizados para analisar informações como a circunferência do crânio, dimensão anteroposterior máxima e dimensão mediolateral máxima. Uma mais-valia do uso deste *scanner* foi a possibilidade de extrair uma medida que manualmente não era possível calcular, o Índice de Simetria Radial, ou seja, a comparação do tamanho de vetores de cada um dos lados da cabeça que vão desde o centro do crânio até às suas extremidades com incrementos de 15° (Figura 32).




Figura 32 – Índice de Simetria Radial (Plank et al., 2006)

Este índice é calculado somando os valores absolutos das diferenças a cada incremento à exceção de 0 e 180°.

A hipótese geral definida é a de que pacientes tratados com a ortótese irão apresentar melhorias significativas na simetria craniana. Para testar esta hipótese, antes da intervenção foram examinadas quais as diferenças entre o grupo de controlo e o grupo de testes, no total, trinta e uma variáveis foram recolhidas com o *scanner* e analisadas principalmente através de

análises de variância, *t-tests* e técnicas de regressão linear múltipla para comparar o grupo de controlo com o grupo de testes e os contrastes pré e pós-tratamento.

No início do estudo não foram detetadas diferenças significativas entre os dois grupos nas variáveis avaliadas, contudo, no final do tratamento foi possível provar a hipótese previamente enunciada sendo as melhorias registadas no grupo de testes expressivamente superiores às do grupo de controlo.

Na Tabela 12, extraída do artigo original deste estudo, é possível observar a quantidade de melhorias ou agravamentos para cada um dos grupos nas quatro variáveis principais: Proporção de Simetria Posterior (PSR)(%), Proporção de Simetria Geral (OSR)(%), Índice de Assimetria da Caixa Craniana (CVAI)(%) e índice de de Simetria Radial (RSI)(mm) (Plank et al., 2006).

Tabela 12 – Quantidade de melhorias/agravamentos registadas para as quatro variáveis chave (Plank et al., 2006)

|                           |      | <i>PSR</i> | <i>OSR</i> | <i>CVAI</i> | <i>RSI</i> |
|---------------------------|------|------------|------------|-------------|------------|
| Subjects who improved     |      |            |            |             |            |
| Treatment                 | N    | 157        | 159        | 157         | 161        |
|                           | Mean | 0.09       | 0.05       | 4.02        | 20.3       |
|                           | Max  | 0.2        | 0.12       | 9.97        | 53.4       |
| Control                   | N    | 10         | 11         | 10          | 10         |
|                           | Mean | 0.0001     | 0.013      | 0.016       | 10.7       |
|                           | Max  | 0.09       | 0.06       | 4.96        | 32         |
| Subjects who became worse |      |            |            |             |            |
| Treatment                 | N    | 6          | 4          | 6           | 2          |
|                           | Mean | -0.038     | -0.02      | -0.52       | -2.1       |
|                           | Max  | -0.065     | -0.03      | -1.27       | -4         |
| Control                   | N    | 6          | 5          | 6           | 6          |
|                           | Mean | -0.019     | -0.08      | -0.989      | -4.55      |
|                           | Max  | -0.027     | -0.014     | -2.604      | -11.4      |

É assim possível concluir que o uso de modelos 3D das cabeças deformadas dos pacientes com PP é uma mais-valia tendo assim acesso a medidas mais exatas e a um acompanhamento mais eficaz, sabendo-se sempre durante a progressão do tratamento quais as medidas que ainda poderão melhorar. Embora este estudo tenha obtido resultados bastante positivos existe ainda espaço para melhorar o passo de construção das ortóteses através de um *design* mais personalizado e automático tendo como base transformações do modelo deformado em modelos normais.

## Apêndice B – Computação da distância de Hausdorff

```
float computeHausdorff(PointCloud<PointXYZ>::Ptr cloud_a,
PointCloud<PointXYZ>::Ptr cloud_b)
{
    const final int k_neighbour = 1;

    // compare A to B
    pcl::search::KdTree<PointXYZ> tree_b;
    tree_b.setInputCloud(cloud_b->makeShared());
    float max_dist_a = -std::numeric_limits<float>::max();
    for (size_t i = 0; i < cloud_a->points.size(); ++i)
    {
        std::vector<int> indices(1);
        std::vector<float> sqr_distances(1);

        tree_b.nearestKSearch(cloud_a->points[i], k_neighbour, indices,
sqr_distances);
        if (sqr_distances[0] > max_dist_a)
            max_dist_a = sqr_distances[0];
    }

    // compare B to A
    pcl::search::KdTree<PointXYZ> tree_a;
    tree_a.setInputCloud(cloud_a->makeShared());
    float max_dist_b = -std::numeric_limits<float>::max();
    for (size_t i = 0; i < cloud_b->points.size(); ++i)
    {
        std::vector<int> indices(1);
        std::vector<float> sqr_distances(1);

        tree_a.nearestKSearch(cloud_b->points[i], k_neighbour, indices,
sqr_distances);
        if (sqr_distances[0] > max_dist_b)
            max_dist_b = sqr_distances[0];
    }

    // final distance
    max_dist_a = std::sqrt(max_dist_a);
    max_dist_b = std::sqrt(max_dist_b);
    float hausdorff_distance = std::max(max_dist_a, max_dist_b);

    return hausdorff_distance;
}
```





## Apêndice C – Cálculo da distância média para o ponto mais próximo

```
float compute_average_distance(pcl::PointCloud<pcl::PointXYZ>::Ptr cloud_a,
pcl::PointCloud<pcl::PointXYZ>::Ptr cloud_b) {

    pcl::KdTreeFLANN<pcl::PointXYZ> kdtree;
    kdtree.setInputCloud(cloud_b);

    int k = 1;
    std::vector<int> pointIdxNKNSearch(k);
    std::vector<float> pointNKNSquaredDistance(k);

    float distancesSum = 0;

    for (int i = 0; i < cloud_a->points.size(); i++){
        pcl::PointXYZ searchPoint = cloud_a->points[i];
        kdtree.nearestKSearch(searchPoint, k, pointIdxNKNSearch,
pointNKNSquaredDistance);
        distancesSum = distancesSum + pointNKNSquaredDistance[0];
    }

    float average_distance = distancesSum / cloud_a->points.size();
    return average_distance;
}
```